

**YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**DALGACIK YAPAY SİNİR AĞLARI VE ÖĞRENME
ALGORİTMASI**

728878

Elektrik Yük. Müh. Abdullah BAL

F.B.E Elektrik Mühendisliği Anabilim Dalında Hazırlanan

DOKTORA TEZİ

**TC YÜKSEK ÖĞRETİM KURULU
DOKÜMAN YERİNE KALIR**

Tez Savunma Tarihi : 29 Mayıs 2002
Tez Danışmanı : Prof. Dr. Halit PASTACI (YTÜ)
İkinci Tez Danışmanı : Doç. Dr. Osman N. UÇAN (İÜ)
Jüri Üyeleri : Prof. Dr. Galip CANSEVER (YTÜ)
: Prof. Dr. Mehmet Akif EYLER (MÜ)
: Prof. Dr. Mahmut ÜN (İÜ)
: Doç. Dr. Mehmet KORÜREK (İTÜ)

Opabag
MAR
Mahmut ÜN
M. Korurek

İSTANBUL, 2002

128818

İÇİNDEKİLER

Sayfa

SİMGE LİSTESİ.....	v
KISALTMA LİSTESİ.....	vi
ŞEKİL LİSTESİ.....	vii
ÇİZELGE LİSTESİ.....	ix
ÖNSÖZ.....	x
ÖZET.....	xi
ABSTRACT.....	xii
1. GİRİŞ.....	1
1.1 Tarihi Gelişim.....	1
1.1.1 Yapay Sinir Ağları.....	1
1.1.2 Hücresel Yapay Sinir Ağı.....	2
1.1.3 Dalgacık Teorisi.....	3
1.2 Amaç ve Yöntem.....	3
1.3 Tezin Bölümleri.....	5
2. YAPAY SİNİR AĞLARI.....	8
2.1 Yapay Sinir Ağlarının Genel Yapısı.....	8
2.2 Yapay Sinir Ağı Modelleri.....	9
2.2.1 İleri Beslemeli Ağlar.....	9
2.2.1.1 Hücre Modeli.....	9
2.2.1.2 Tek Katmanlı İleri Beslemeli Ağlar.....	10
2.2.1.3 Çok Katmanlı İleri Beslemeli Ağlar.....	11
2.2.2 Geri Beslemeli Ağlar.....	12
2.3 Yapay Sinir Ağlarında Öğrenme.....	13
2.3.1 Eğitici Öğrenme.....	14
2.3.2 Eğitici Öğrenme.....	14
2.4 Öğrenme Kuralları.....	15
2.5 Öğrenme Faktörleri.....	21
2.5.1 Yakınsama.....	21
2.5.2 İlk Ağırlıklar.....	22
2.5.3 Öğrenme Oranı.....	22
3. DALGACIK TEORİSİ.....	23
3.1 Dalgacık Fonksiyonları.....	23
3.2 Dalgacık Dönüşümü.....	25
3.2.1 Sürekli Dalgacık Dönüşümü.....	27
3.2.2 Ayrık Dalgacık Dönüşümü.....	30
4. DALGACIK YAPAY SİNİR AĞI.....	34
4.1 Dalgacık Yapay Sinir Ağının Mimarisi.....	34
4.2 Dalgacık Yapay Sinir Ağının Eğitimi.....	37
4.3 Dalgacık Yapay Sinir Ağının Performans Analizi.....	40

4.3.1	Elektromiyografik İşaretlerin Sınıflandırılması Problemi.....	40
4.3.1.1	Elektromiyografik işaret nedir?.....	40
4.3.1.2	EMG işaretlerinin Modellenmesi	41
4.3.1.3	AR Katsayıları.....	41
4.3.1.4	EMG İşarelerinin Yapay Sinir Ağlarına Uygulanması	42
4.3.1.5	Eğitme ve Test Sonuçları	45
4.3.2	Fonksiyon Yaklaşımı Problemi.....	46
4.3.3	Aydınlık Düzeyi Hesabı	53
4.3.3.1	Aydınlık Düzeyi	53
4.3.3.2	Işık Dağılım Eğrileri.....	54
4.3.3.3	Aydınlık Düzeyi Hesabının Yapay Sinir Ağları Kullanılarak Gerçeklenmesi.....	55
5.	HÜCRESEL YAPAY SİNİR AĞI	60
5.1	Hücrel Yapay Sinir Ağı Mimarisi.....	60
5.2	Hücre Yapıları	61
5.3	Hücrel Yapay Sinir Ağlarında Komşuluk İlişkisi	62
5.4	Hücrel Yapay Sinir Ağına Devresel Gösterimi	63
5.5	Diferansiyel Denklemlerin Fark Denklemleri Olarak Gösterilmesi.....	66
5.6	Hücrel Yapay Sinir Ağlarında Kararlılık.....	67
5.7	Hücrel Yapay Sinir Ağına Sürekli Zaman Analizi.....	68
6.	DALGACIK HÜCRESEL YAPAY SİNİR AĞI	69
6.1	Dalgacık Öğrenme Algoritması.....	69
6.1.1	Dalgacık Hücrel Yapay Sinir Ağı Mimarisi	77
7.	GÖRÜNTÜ İŞLEME UYGULAMALARI	79
7.1	Kenar Belirleme	79
7.1.1	DHYSA'nın Eğitim Aşaması	81
7.1.2	DHYSA'nın Test Aşaması	82
7.1.2.1	Sentetik Görüntüler	82
7.1.2.2	Kamera ile Alınan Görüntüler.....	82
7.1.2.3	Tıbbi Görüntüler.....	82
7.2	Jeofizik Verilerinin Analizi	88
7.2.1	Gravite Yöntemi.....	88
7.2.1.1	Gravitenin Temel İlkesi.....	89
7.2.1.2	Potansiyel Teori.....	90
7.2.1.3	Model Çalışma Yöntemi	91
7.2.2	Manyetik Yöntem.....	92
7.2.3	HYSYA'nın Jeofizik Verilere Uygulanması.....	93
7.2.3.1	Dumluca Demir Madeni Sahasının Manyetik Anomali Haritası Analizi.....	96
7.3	Arkeolojik Görüntülerin Analizi	99
8.	SONUÇLAR	105
8.1	Dalgacık Yapay Sinir Ağı	105
8.2	Dalgacık Öğrenme Algoritması ve Dalgacık Hücrel Yapay Sinir Ağı	106
8.2.1	Kenar Belirleme	107
8.2.2	Jeofizik Verilerin Analizi	108
8.2.3	Arkeolojik Görüntülerin Analizi	108
KAYNAKLAR.....		110
EKLER.....		116

Ek 1 EMG İşaretlerinin Sınıflandırılması için Veritabanı	117
Ek 2 DHYSA Eğitim Programı	118
Ek 3 DHYSA Test Programı	123
Ek 4 Klasik Yöntemler ile Kenar Belirleme Programı	125
ÖZGEÇMİŞ	126



TC. YÜKSEKÖĞRETİM KURULU
DOKÜMANTASYON MERKEZİ

SİMGE LİSTESİ

ω	Yapay sinir ağlarında ağırlık katsayıları
b	Yapay sinir ağlarında eşik katsayısı
n	Yapay sinir ağlarında ağırlıklı toplam
$\rho(.)$	YSA'da giriş ile çıkış arasındaki yaklaşım kalitesini veren fonksiyon
t	Yapay sinir ağlarının öğrenmesinde hedef çıkışlar
k	İleri beslemeli ağlarda iterasyon sayısı
α	YSA'da öğrenme oranı
ψ	Dalgacık fonksiyonu
I	Işık şiddeti
E	Noktasal aydınlık düzeyi
r	Işık kaynağı ile aydınlık düzeyinin hesaplanacağı nokta arasındaki mesafe
h	Işık kaynağının yerden yüksekliği,
$Y_{i,j}^k$	HYSA giriş matrisi
$x_{i,j}^k$	HYSA başlangıç matrisi
$y_{i,j}^k(\infty)$	HYSA'nın k. İterasyon sonucunda kararlı durum çıkışı
g	Yerçekimi ivmesi

KISALTMA LİSTESİ

A	HYSA'da kullanılan geri besleme matrisi
ADD	Ayrık Dalgacık Dönüşümü
B	HYSA'da kullanılan durum matrisi
C	DHYSA'da kullanılan şablon matrisi
ÇKA	Çok katmanlı ağ
DHYSA	Dalgacık Hücresel Yapay Sinir Ağı
DÖA	Dalgacık Öğrenme Algoritması
DYSA	Dalgacık Yapay Sinir Ağı
FD	Fourier Dönüşümü
GYA	Geriye yayılım algoritması
HYSA	Hücresel Yapay Sinir Ağı
I	HYSA eşik değeri
İBA	İleri Beslemeli Ağlar
KZFD	Kısa-Zaman Fourier Dönüşümü
YSA	Yapay Sinir Ağları

ŞEKİL LİSTESİ

Şekil 2.1	YSA hücre modeli	9
Şekil 2.2	Tek katmanlı ileri beslemeli ağ	11
Şekil 2.3	Çok katmanlı YSA mimarisi	12
Şekil 2.4	Geri beslemeli ağ mimarisi.....	13
Şekil 2.5	(a) Eğiticili,(b) Eğiticisiz öğrenme algoritmaları blok şemaları.....	14
Şekil 2.6	İki boyutlu uzayda giriş örnekleri: (a) Kümelenmiş (b) Belirli kümeler yok (Genç,1996)	15
Şekil 3.1	Kübik B-spline dalgacık	24
Şekil 3.2	Morlet Dalgacığı.....	25
Şekil 3.3	Fourier ve dalgacık dönüşümünün zaman - frekans hücreleri.....	27
Şekil 3.4	Morlet Dalgacığının farklı genişleme değerlerine göre değişimi ($a=1/2$ ve $a=3$) ⁹	
Şekil 3.5	Ayrık dalgacık dönüşümünün FIR filtre karşılığı (Engin, 1997).	30
Şekil 3.6	Filtre bankaları kullanılarak ADD'nün altbandlara ayrışım yöntemi olarak uygulanması (Engin, 1997).....	32
Şekil 3.7	ADD'nin frekans domeni ayrımı (Engin, 1997).....	33
Şekil 4.1	ÇKA'da kullanılan aktivasyon fonksiyonları, a)Lineer, b)Logaritmik sigmoid, c) Hiperbolik tanjant sigmoid.....	35
Şekil 4.2	Meksika şapkası fonksiyonu.....	36
Şekil 4.3	DYSA'nın mimarisi.....	36
Şekil 4.4	ADD filtre bankası.....	38
Şekil 4.5	ADD nin ikili alt örnekleme gösterimi	38
Şekil 4.6	a) 1.Sınıfa ait kolu içe hareket ettirme işareti, b) 2. Sınıfa ait kolu dışa hareket ettirme işareti, c) 3. Sınıfa ait dirsek açma işareti, d) 4. Sınıfa ait dirsek kapama işareti	43
Şekil 4.7	EMG işaretlerinin 1., 2. ve 3. AR katsayılarına göre sınıfsal dağılımı	43
Şekil 4.8	EMG işaretlerinin 1., 2. ve 4. AR katsayılarına göre sınıfsal dağılımı	44
Şekil 4.9	EMG işaretlerinin 1., 3. ve 4. AR katsayılarına göre sınıfsal dağılımı	44
Şekil 4.10	EMG işaretlerinin 2., 3. ve 4. AR katsayılarına göre sınıfsal dağılımı	45
Şekil 4.11	ÇKA ¹ 'in eğitimi sonucu bulunan y_1 fonksiyonu ile orijinal y fonksiyonunun birlikte gösterimi.....	49
Şekil 4.12	ÇKA ² 'nin eğitimi sonucu bulunan y_2 fonksiyonu ile orijinal y fonksiyonunun birlikte gösterimi.....	49
Şekil 4.13	DYSA'nın eğitimi sonucu bulunan y_3 fonksiyonu ile orijinal y fonksiyonunun birlikte gösterimi.....	50
Şekil 4.14	Eğitim sonucunda hatanın iterasyon sayısına göre değişimi	51
Şekil 4.15	ÇKA ¹ 'in test sonuçları ile orijinal y fonksiyonunun birlikte gösterimi.....	52
Şekil 4.16	ÇKA ² 'nin test sonuçları ile orijinal y fonksiyonunun birlikte gösterimi.....	52
Şekil 4.17	DYSA'nın test sonuçları ile orijinal y fonksiyonunun birlikte gösterimi	53
Şekil 4.18	Aydınlık düzeyi hesaplanacak noktanın konumu	54
Şekil 4.19	İncelenen ışık kaynağının ışık dağılım eğrisi	56
Şekil 4.20	Eğitim kümesi olarak kullanılan 11 noktanın aydınlatma şiddetleri	56
Şekil 4.21	DYSA test sonuçları	57
Şekil 4.22	DYSA test sonuçları ile orijinal verilerin birlikte gösterilimi	57
Şekil 4.23	Aydınlık düzeyleri hesaplanan noktalar	58
Şekil 4.24	x-ekseni üzerindeki noktaların aydınlık düzeyleri.....	59
Şekil 5.1	4x4 Boyutunda bir hücreyel yapay sinir ağı gösterimi.	60
Şekil 5.2	Bir hücrenin dinamik yapısı	61
Şekil 5.3	Hücreyel yapay sinir ağlarında komşuluk.....	62
Şekil 5.4	$r=1$ Komşuluğunda heksagonal yapıya sahip hücreyel yapay sinir ağı	63

Şekil 5.5	Bir hücre yapısının devresel olarak gösterilmesi.....	64
Şekil 5.6	Parça-parça doğrusal çıkış karakteristiği	64
Şekil 6.1	HYSA aktivasyon fonksiyonu	70
Şekil 6.2	$a = 0.1$ ve $b = 2$ için Meksika Şapkası dalgacığı	71
Şekil 6.3	Kararlı durum çıkışlarını üreten ileri yönlü algoritmanın akış diyagramı.....	75
Şekil 6.4	Hatayı minimize etmeye yönelik geriye yayılım akış diyagramı	77
Şekil 6.5	DHYSA'nın mimarisi.....	78
Şekil 7.1	a) Eğitim amaçlı 16×16 'lık giriş görüntüsü, b) Eğitim aşamasındaki hedef görüntü.....	81
Şekil 7.2	a) Giriş görüntüleri, b) DHYSA sonuçları.....	83
Şekil 7.3	a) Giriş görüntüleri, b) DHYSA sonuçları, c) Canny sonuçları, d) Sobel sonuçları e) Laplasyen sonuçları	84
Şekil 7.4	a) 256×256 Boyutlu pirinç görüntüsü, b) DHYSA sonuçları, c) Canny sonuçları, d) Sobel sonuçları e) Laplasyen sonuçları	85
Şekil 7.5	a) 256×256 Boyutlu damla görüntüsü, b) DHYSA sonuçları, c) Canny sonuçları, d) Sobel sonuçları e) Laplasyen sonuçları	86
Şekil 7.6	a) 256×256 boyutlu MR görüntüsü, b) DHYSA sonuçları, c) Canny sonuçları, d) Sobel sonuçları e) Laplasyen sonuçları	87
Şekil 7.7	'P' Noktasının yeryüzü düzleminde gösterimi.	92
Şekil 7.8	İki kürenin ayrı ayrı gravite etkileri.....	94
Şekil 7.9	İki kürenin toplam gravite etkileri	95
Şekil 7.10	Dumluca maden yatağının jeoloji haritası	97
Şekil 7.11	Dumluca maden yatağının MTA sondaj sonuçları	97
Şekil 7.12	Dumluca maden yatağının manyetik anomaly haritası ve HYSA ayırım sonucu.....	98
Şekil 7.13	Dumluca maden yatağı analizinde Haalck'ın türev metodu sonucu	99
Şekil 7.14.	Büyük Hitit İmparatorluğu'nun toprak ve önemli yerleşim yerleri.....	100
Şekil 7.15.	Sivas-Kuşaklı bölgesinin topografik haritası.....	100
Şekil 7.16	Hitit uygarlığına ait Kuşaklı Bölgesi Arkeolojik duvar görüntüsü ve HYSA analizi sonucu	102

ÇİZELGE LİSTESİ

Çizelge 4.1	ÇKA ¹ , ÇKA ² ve DYSA'nın gizli katman düğüm sayılarının farklı değerleri için eğitim iterasyon sayıları.....	46
Çizelge 4.2	ÇKA ¹ , ÇKA ² ve DYSA'nın gizli katman düğüm sayılarının farklı değerleri için saniye cinsinden eğitim süreleri	46
Çizelge 4.3	ÇKA1, ÇKA2 ve DYSA'nın $\alpha=0.05$ ve $\alpha=0.1$ öğrenme oranları için eğitim sonuçları.....	48
Çizelge 4.4	Eğitme aşaması iterasyon sonuçları.....	57
Çizelge 4.5	E(x,y) aydınlık düzeyleri	58
Çizelge 7.1	Sentetik bouguer anomali haritasının parametreleri.....	93



ÖNSÖZ

Tez çalışmalarım sırasında benden yardımlarını ve desteklerini esirgemeyen sayın hocam Prof. Dr. Halit PASTACI ve Doç. Dr. Osman N. UÇAN'a, jeofizik alanındaki çalışmalarımda çok değerli görüş ve bilgilerinden yararlandığım sayın Y.Doç.Dr. Muhittin ALBORA, Y.Doç.Dr Z.Mümtaz Hisarlı ve yardımsever meslektaşım Dr. Atilla ÖZMEN'e en içten teşekkürlerimi sunarım.

Ayrıca gösterdikleri anlayış, sağladıkları ortam ve motivasyon için aileme teşekkür etmeyi borç bilirim.

Ocak 2002

Abdullah BAL



ÖZET

Yapay sinir ağlarında mevcut bulunan, eğitim süresinin uzun olması, kararsızlık bölgelerine yakalanabilmesi veya daha küçük boyutlara indirgenememesi gibi problemlerin çözümlenmesine yönelik yeni ağ mimarileri geliştirme ve öğrenme algoritmaları oluşturma çalışmaları günümüzde sürdürülmektedir. Bu çalışmalarda, genellikle izlenen yol farklı yöntemlerin birlikte kullanılması şeklinde olmaktadır. Dalgacık teorisi ile ileri ve geri beslemeli ağların birlikte kullanılmaları esasına dayanan bu tez* çalışması da yukarıdaki problemleri çözmeye yönelik bu tür bir çalışmadır.

Tezi iki ana bölüme ayırmak mümkündür: İlk bölümde, ileri beslemeli ağlar ile dalgacık teorisinin hibrid bir yapı içerisinde birlikte kullanılmaları üzerinde durulmuştur. Ağın iç yapısında transfer işlem birimi olarak dalgacık fonksiyonlarının kullanılması ile eğitim hızı artırılmış ve daha küçük boyutlu ağ mimarilerinin elde edilmesine olanak sağlanmıştır. Bu ağ, “Dalgacık Yapay Sinir Ağı” olarak adlandırılmış ve performans analizi için elektromiyogram işaretlerin sınıflandırılması, fonksiyon yaklaşımı ve aydınlık düzeyi hesaplanması gibi farklı alanlarda uygulamalar yapılmıştır.

Tezin ikinci bölümünde ise hücrel yapay sinir ağı, dalgacık teorisi ve geriye yayılım algoritmasının birlikte kullanımı ile yeni bir ağ mimarisi ve öğrenme algoritması elde edilmiştir. “Dalgacık Hücrel Yapay Sinir Ağı” ve “Dalgacık Öğrenme Algoritması” olarak adlandırılan bu yapılar kullanılarak farklı görüntü işleme uygulamaları gerçekleştirilmiştir. Görüntü bölütleme tekniklerinden olan kenar belirleme uygulamasında, sentetik görüntü, kamera ve tıbbi görüntüler kullanılmıştır. Diğer bir önemli uygulama alanı olarak da jeofizik maden haritalarının ayrıştırılması ve arkeolojik görüntülerin iyileştirilmesi seçilmiştir. Elde edilen sonuçlar ile klasik yöntemlerin sonuçları karşılaştırıldığında yeni mimari ve öğrenme algoritmasının daha başarılı olduğu görülmüştür.

Anahtar Kelimeler: Yapay sinir ağları, dalgacık teorisi, geriye yayılım algoritması, hücrel yapay sinir ağı, jeofizik maden haritaları, arkeolojik görüntüler

* Bu tez çalışması TÜBİTAK tarafından desteklenmiştir. Proje No:101Y063

ABSTRACT

The studies on development of novel network architecture and learning algorithms have long been carried out, not only in the past but also nowadays, so that the network can be reduced to small-scale structure with short-time training and without catching in instability regions. In general, the method used in the studies is to combine different techniques in hybrid structure. This thesis* develops a hybrid network architecture consist of feed-forward and dynamic networks and wavelet theory in aiming to solve aforementioned problems.

This thesis can be divided into two main sections. In the first section, feed-forward network and wavelet theory are considered in a hybrid structure. Training speed is increased by using wavelet functions as transfer operation unit in the network and small-scale network architectures are formed accordingly. This network is called “Wave-Net” and applied to different areas such as function approximation, calculation of illumination level and performance analyze for the classification of electromyography signals.

In the second section, a new learning algorithm and network architecture are obtained by using cellular neural network, wavelet theory and backpropagation algorithm all together. The structures are called “Wave-CNN” and “Wavelet learning algorithm” and applied to different image processing applications such as bio-medical image, video camera image, artificial image and edge detection which is used in image segmentation field. Geophysics mine maps separation and archeological image enhancement are selected for other important application areas. Comparing the proposed method with conventional ones in the thesis, it is shown that the developed method is quite better.

Keywords: Artificial neural network, wavelet theory, backpropagation algorithm, cellular neural network, geophysics mine maps, archeological images.

* This thesis was supported by The Scientific and Technical Research Council of Turkey (TUBITAK).
Project Number: 101Y063

1. GİRİŞ

Günümüzde bilgisayar teknolojisinin hızlı gelişimi ve buna paralel olarak çok fazla işlem yapabilme olanağının elde edilmesi yeni yöntemlerin bilim dünyasına kazandırılmasına imkan sağlamıştır. *Yapay sinir ağları, dalgacık teorisi, bulanık mantık ve genetik algoritmalar* bu yöntemlere örnek olarak verilebilirler. Bu yöntemlerin ortak özelliği çok farklı bilim dallarında başarılı bir şekilde kullanım alanına sahip olmalarıdır. Bu özellikleri, araştırmacıları yeni uygulama alanları araştırmalarına ve birlikte kullanımları ile daha iyi sonuçlar veren yeni yöntemlerin geliştirilmesine teşvik etmiştir. Nöral-bulanık sistemler, dalgacık - yapay sinir ağları, genetik – yapay sinir ağları, genetik-bulanık sistemler bu türlü çalışmalara örnek olarak verilebilirler. Bu tez çalışmasında da bu yöntemlerden yapay sinir ağları, hücresel yapay sinir ağı ve dalgacık teorisinin birlikte kullanılabilmesi ve yeni uygulama alanları üzerinde durulmuştur. Çalışmanın içeriğine geçmeden önce kullanılan yöntemlerin tarihsel gelişimi ve daha önce yapılmış çalışmaların incelenmesinde fayda olacaktır.

1.1 Tarihi Gelişim

1.1.1 Yapay Sinir Ağları

Yukarıda adı geçen yöntemlerden en önemlisi diyebileceğimiz yapay sinir ağlarının (YSA) gelişiminin başlangıç yılı 1943 olarak kabul edilir. Bu tarihte McCulloch ve Pitts, YSA'nın temeli sayılan ilk hücre modelini geliştirmiş ve birkaç hücrenin ara bağlaşımını incelemişlerdir. Hebb, 1949 yılında hücre bağlantılarını ayarlamak için ilk öğrenme kuralını önermiştir. Bu kural ile ağın istenen kısıtlamalar altında giriş-çıkış bağıntısının elde edilmesi sağlanabilmiştir.

1958'te Rosenblatt, algılayıcı (Perceptron) modelini ve öğrenme kuralını geliştirmiştir. Bu çalışma bugün kullanılan kuralların temellerini oluşturmaktadır. Minsky ve Papert, 1969 yılında, algılayıcının kesin analizini yapmışlar ve algılayıcının karmaşık mantık fonksiyonlar için kullanılamayacağını ispatlamışlardır.

Bunun üzerine, YSA ile ilgili yapılan araştırmalar hemen hemen durmuştur. Ancak bazı bilim adamlarının çalışmaları sonucu 1976'da Grossberg, Adaptif Rezonans Teoriyi (ART), 1982'de Hopfield, optimizasyon gibi teknik problemleri çözmek için lineer olmayan dinamik Hopfield Ağını ve 1984'de Kohonen, eğiticişiz öğrenen bir ağı geliştirmişlerdir.

1986 yılında, Rumelhart, esas olarak 1974 yılında Werbos tarafından bulunan çok katmanlı algılayıcı tipi ağlar için geriye yayılma algoritması denen bir eğitim algoritması geliştirmiştir. Bu çalışmayla, YSA alanında bir çığır açılmıştır. Bugün en çok kullanılan algoritma olan geriye yayılım algoritması hatayı minimize etmeye yönelik ağırlıkların çıkıştan girişe doğru ayarlanması esasına dayanmaktadır (Özyılmaz, 2000).

1.1.2 Hücresel Yapay Sinir Ağı

Hücresel Yapay Sinir Ağı (HYSA), ilk olarak 1988 yılında Leon Chua ve Lin Yang tarafından ortaya atılan ve Hopfield'ın geliştirdiği dinamik ağlar sınıfından olan yeni bir ağ yapısıdır. Bu ağın hücre yapısından dolayı iki boyutlu işaretlerin işlenmesinde, özellikle de görüntü üzerine yapılan çalışmalarda büyük bir başarı ile kullanılabildiği görülmüştür. HYSA'nın bir diğer önemli özelliği de tümleşik devre olarak kolay bir şekilde uygulanabilmesidir.

HYSA'nın dinamik yapısından dolayı girişler çıkışa bağlı olarak değişmektedir. Bu ilişki, ağın eğitiminin de farklı olmasını gerektirmektedir. Tasarım geliştirmeye yönelik yapılan çalışmalarda değişik yöntemler ileri sürülmüştür. Bu yöntemlerden Chua'nın (1990) önerdiği yöntem, deneme yanılmaya ve 2-boyutlu doğrusal filtreler ile benzerlik kurmaya dayalıdır. Vanderberghe (1989) ve Zou'nun (1990) geliştirdiği yöntemler verilen bir giriş için istenen çıkışları kalıcı durum çıkışları olarak veren bağlantı ağırlıklarının bulunması problemini bir doğrusal eşitsizlik takımının çözümünün elde edilmesi problemine indirgemektedir. Schuler'in (1992) yöntemi ise istenen bir kalıcı durum çıkışının değil de istenen bir yörüngenin öğretilmesi amacı ile geliştirilmiştir. Karamahmut ve Güzeliş'in (1994) geliştirmiş olduğu eğiticili öğrenme algoritmalarında ileri yönlü ağlarda kullanılan öğrenme algoritmalarının dinamik ağlara uyarlanması üzerinde çalışılmıştır. Bu çalışmada HYSA'nın aktivasyon fonksiyonu için farklı bir fonksiyon seçilmiş ve yeni ağırlıkların ayarlanmasını sağlayan eşitlikte hata ve başlangıç değerleri kullanılmayarak öğrenme gerçekleştirilmiştir. Çelebi ve Güzeliş (1997) görüntü onarımına yönelik Lyapunov işlev tabanlı tasarım yöntemini geliştirmişlerdir. P.Lopez , M. Balsi ve F.Voci (2000) genetik algortimaların ve bulanık mantık kurallarının HYSA'nın eğitim ve tasarımında kullanımı üzerinde çalışmışlardır (Güzeliş, 1996).

1.1.3 Dalgacık Teorisi

Yapay sinir ağlarında giriş kümelerinin seçimi ve boyutu çok önemlidir. Minimum boyutta giriş kümesi ile maksimum karakteristik özelliğin ifade edilebilmesi istenir. Bu amaç için kullanılan birçok dönüşüm yöntemleri ve modelleme teknikleri geliştirilmiştir. Dalgacık (Wavelet) teorisi bu yöntemler içinde sayabilecek en yeni ve en güçlü bir metoddur. 80'li yılların başında Grossman ve Morletin dalgacık adı verilen fonksiyonları sismik işaretlerin modellenmesinde kullanımı ile başlayan çalışmalar Daubechies (1988), Mallat (1989) ve Meyer (1993) tarafından devam ettirilmiştir. Bu çalışmalar sonucunda elde edilen dalgacık dönüşümü ve dalgacık fonksiyonları ile işaret analizinde, altband ayrışımında ve öznitelik vektörlerinin elde edilmesinde üstün performansı ortaya konmuştur (Rao ve Bopardikar, 1998).

1.2 Amaç ve Yöntem

Dalgacık dönüşümü ve yapay sinir ağlarının bir çok ortak uygulama alanlarının bulunmasından dolayı bu yöntemlerin birlikte kullanımı literatürde önemli bir yere sahiptir. Genellikle dalgacık dönüşümü özellik çıkarımı amaçlı kullanılır. Elde edilen özellik vektörleri yapay sinir ağlarında giriş kümesi olarak kullanılır. Böylelikle giriş düğüm sayısı ve işlem süresi azaltılmış olur. Bunun yanı sıra dalgacık ayrışımının yapay sinir ağlarının yapısı içinde kullanımı konusunda sınırlı sayıda çalışmalar yapılmıştır. Bu çalışmalarda farklı ağ yapıları ve farklı öğrenme algoritmaları kullanılarak yeni ağ mimarileri geliştirilmiştir. Bu yeni ağların kullanımının klasik ağlara göre hız, boyut, yakınsama gibi konularda daha iyi sonuçlar verdiği ortaya konmuştur.

Bu tez çalışmasında öncelikle, yukarıda bahsi geçen HYSA'nın eğitimi ve mimarisinin geliştirilmesi hedeflenmiştir. Bu amaçla HYSA, dalgacık teorisi ve geriye yayılım algoritmaları üzerinde durulmuştur. Çalışmalar esnasında öncelikle dalgacık teorisinin ileri beslemeli ağlar (İBA) ile kullanımında nasıl sonuçlar vereceği incelenmiştir. Bu konuda literatürde yapılan çalışmalar incelendiğinde Zhang Q. ve Benveniste A. sürekli dalgacık dönüşümünü esas alan $(1+1/2)$ katmanlı farklı bir bağlantı mimarisine sahip ağ yapısı geliştirdiği görülmüştür. Javier E.'nin ortaya koyduğu ağ yapısında, radial temelli ağlarda costrap dalgacığının kullanımı gerçekleşmiş ve biyomedikal işaretlerin işlenmesinde kullanımı gösterilmiştir. Yao S. ve Wei C.J. tarafından gerçekleştirilen ağ yapısında dalgacıklar ile optimizasyon tekniğine dayalı öğrenme yönteminin birlikte kullanımı ortaya konmuştur.

Bu çalışmalar ışığında geliştirilen *Dalgacık Yapay Sinir Ağında (DYSA)*, dalgacıkların çok katmanlı ağda (ÇKA) aktivasyon fonksiyonu olarak kullanımı ve geriye yayılım algoritması ile ağırlıkların ayarlanması sağlanmıştır. Bu ağ yapısı kullanılarak fonksiyon yaklaşımı, biyomedikal işaretlerin sınıflanması ve aydınlatma problemlerinin çözümünde kullanımı üzerinde uygulamalar yapılmıştır. Bu uygulamalar sonucunda elde edilen başarılı sonuçlar dalgacık teorisi ile HYSYA'nın birlikte kullanılmasına teşvik edici nitelikte olmuştur. Bu geçişi yapabilmek için HYSYA'nın yapısının İBA'ya uyarlanması gerekmektedir. Bu uyarılama için İBA ile HYSYA arasındaki farklılıkların bilinmesinde fayda vardır.

a- HYSYA dinamik ağ yapısına sahiptir. Bu ağ yapısından dolayı giriş kümeleri çıkışlara bağlı olarak iteratif olarak değişmektedir. İBA'da ise giriş kümeleri sabittir ve çıkış ile değişmezler.

b- HYSYA ağırlık katsayıları şablon yapısına sahiptir. Bu katsayılar matrisi, bir çeşit iki boyutlu filtre yapısına benzemektedir. İBA'da ise ağırlık katsayıları düğüm sayılarına bağlı olarak farklı boyutlarda olabilmektedir.

c- Şablon yapılarından dolayı katsayıların ayarlanmasında konvolüsyon işleminin kullanılmasını zorunludur. İBA'da ise bu işlem matris çarpımları şeklinde gerçekleşmektedir.

Bu farklılıklar gözönünde bulundurularak İBA'da yaygın kullanımı olan geriye yayılım algoritmasının bu yapıya uyarlanması ve dalgacık fonksiyonlarının bu algorithmada kullanımı üzerinde çalışılmıştır. Bu çalışmalar sonucunda *Dalgacık Öğrenme Algoritması (DÖA)* geliştirilmiştir. Bu yeni öğrenme algoritması kullanılarak aşağıdaki uygulama ve analizler yapılmıştır:

a- HYSYA'nın sentetik görüntüler üzerinde eğitim ve test sonuçları analiz edilmiştir.

b- Sentetik görüntüler üzerinde yapılan çalışmalardan sonra gerçek görüntülerin bölütlenmesi ve tıbbi görüntülerin analizi gerçekleştirilmiştir.

c- Jeofizikte kullanılan gravite (bouguer) ve manyetik haritalama yöntemi ile elde edilmiş verilerin analizine yönelik çalışmalar yapılmıştır. Bu çalışmalar ile yer altı maden yerlerinin belirlenmesi sağlanmıştır.

d- Manyetik yöntemler kullanılarak elde edilmiş yer altı arkeolojik görüntülerin iyileştirilmesi gerçekleştirilmiştir.

e- DÖA'nın kullanımı ile HYSYA'nın mimarisinin küçültülmesi üzerinde çalışılmıştır.

Şablon sayısı azaltılarak *Dalgacık Hücresel Yapay Sinir Ağı (DHYSA)* elde edilmiştir. DHYSA'nın görüntü işleme uygulamalarında nasıl sonuçlar verdiği incelenmiştir.

1.3 Tezin Bölümleri

Bölüm 1 - Giriş

Bu tez çalışmasında kullanılacak olan yapay sinir ağları, hücresel yapay sinir ağı ve dalgacık teorisinin gelişim süreçleri tarihsel bir sıra ile verilmiştir. Bu sürecin getirmiş olduğu noktada bu tez çalışması ile nasıl bir katkının amaçlandığı, bu doğrultuda kullanılan yöntemler ve gerçekleştirilen uygulamalar kısaca anlatılmıştır.

Bölüm 2 - Yapay Sinir Ağları

Yapay sinir ağlarının tanımı yapıldıktan sonra, temel ağ modellerinin matematiksel eşitlikleri ile birlikte çalışma sistemleri anlatılmıştır. Bu ağların çalışmasının temelini oluşturan öğrenme konusu işlenmiş ve bu tez çalışmasında kullanılacağından dolayı geriye yayılım algoritmasının işleyişi anlatılmıştır. Son olarak öğrenme üzerinde etkili olan faktörler üzerinde durulmuş, sıra ile yakınsama, ilk ağırlıklar ve öğrenme oranı ile ilgili bilgiler verilmiştir.

Bölüm 3 - Dalgacık Teorisi

Dalgacık teorisinin en yaygın kullanım alanı olan dönüşüm yöntemleri üzerinde durulmuştur. Dönüşüm yöntemlerinde kullanılan dalgacık fonksiyonlarının temel özellikleri anlatıldıktan sonra sürekli dalgacık dönüşümü ve ayrık dalgacık dönüşümü açıklanmıştır.

Bölüm 4 - Dalgacık Yapay Sinir Ağı

Öncelikle dalgacık yapay sinir ağının (DYSA) mimarisi anlatılmış ve bu ağın eğitiminde kullanılan öğrenme algoritmasının işleyişi sunulmuştur. Bu bölümün ikinci kısmında DYSA'nın performans analizi yapılmıştır. Bu analiz için üç uygulama alanı seçilmiştir:

I - Elektromiyografik işaretlerin sınıflandırılması

Elektromiyografik (EMG) işaretlerin tanımı ve modellenmesi anlatıldıktan sonra YSA'ya uygulanması incelenmiştir.

II- Fonksiyon yaklaşımı

Bilinen bir fonksiyonun yapay sinir ağları kullanılarak aktivasyon fonksiyonları ve ağırlık

katsayıları ile ifade edilmesi sağlanmıştır. Bu uygulama sonucunda bulunan bu yeni fonksiyon ile orijinal fonksiyon arasındaki hata ve ağların yakınsama hızları grafikler kullanılarak karşılaştırılmalı olarak sunulmuştur.

III- Aydınlatma ışık dağılım eğrilerinin bulunması

Işık dağılım eğrilerinin ölçüm sonucunda bulunan değerlerinden diğer açılara ait değerlere ulaşmada kullanılan interpolasyon eğrilerine alternatif olarak yapay sinir ağlarının kullanımı ele alınmıştır. Öncelikle ışık dağılım eğrilerinin tanımı ve bu alanda kullanılan yöntemler anlatılmıştır. Daha sonra DYSA ve diğer ağ yapıları kullanılarak yapılan uygulamada ağların eğitim performansları karşılaştırılmıştır.

Bölüm 5 - Hücresel Yapay Sinir Ağı

Dinamik yapay sinir ağları sınıfına ait olan bu yeni ağ yapısının genel tanımlaması yapılmıştır. Bu ağın mimarisi, hücre yapıları, komşuluk ilişkisi, devresel gösterimi, kararlılık durumu ve sürekli zaman analizi anlatılmıştır.

Bölüm 6 - Dalgacık Öğrenme Algoritması

Bu bölümde tezin asıl çalışma alanı olan yeni öğrenme algoritmasının yapısı, işleyişi ve uygulamaları ele alınmıştır. Öncelikle Dalgacık Öğrenme Algoritmasının oluşturulmasında karşılaşılan problemler ve çözüm adımları sunulmuştur. Bu aşamada dalgacık fonksiyonlarının kullanımı ve seçilen dalgacık fonksiyonun özellikleri belirtilmiştir.

Bölümün ikinci kısmında bu algoritmanın kullanımı ile HYSA'nın mimarisi küçültülerek Dalgacık Hücresel Yapay Sinir Ağı (DHYSA) elde edilmiştir. Bu ağın özellikleri ve uygulama alanları üzerinde durulmuştur.

Bölüm 7 – Görüntü İşleme Uygulamaları

Oluşturulan yeni Dalgacık Öğrenme Algoritması ve DHYSA kullanılarak farklı görüntü işleme uygulamaları yapılmıştır. Ağların eğitimi için sentetik görüntülerin seçimi ve eğitim sonucunda bulunan filtre katsayılarının test fazında kullanımı anlatılmıştır. DHYSA ile görüntü kenar belirleme uygulamaları sentetik, kamera ve tıbbi görüntüler kullanılarak yapılmıştır. Sonuçlar klasik kenar belirleme yöntemlerinin sonuçları ile karşılaştırılmıştır.

Dalgacık öğrenme algoritması kullanılarak ilk kez eğitimi HYSA ile jeofizik ve arkeolojik görüntülerin analizi gerçekleştirilmiştir. Jeofizik maden haritalarının ayrıştırılması ve arkeolojik görüntülerin iyileştirilmesinde başarılı sonuçlar elde edildiği görülmüştür.

Bölüm 8- Sonuçlar

Çalışma süresince elde edilen sonuçlar yorumlanarak, yapılan çalışmaların neler kazandırdığı vurgulanmıştır. Klasik yöntemler kullanılarak elde edilen sonuçlar ile karşılaştırmalar yapılmıştır.



2. YAPAY SİNİR AĞLARI

Yapay sinir ağları (YSA), bilgisayar dünyasında insan beyninin ve sinir sisteminin davranışlarını modelleme esası üzerine kurulmuş yeni bir bilgi işleme yöntemidir. Bu ağlar, birbirine paralel olarak çalışan işlem elemanlarından (yapay sinir hücreleri) ve bunların belli bir sıra ile işlem operasyonuna tabi tutulmalarından oluşurlar. Hücreler birbirine bağlı ve paralel çalıştıkları için bazılarının işlevini yitirmesi ile sinir sistemi fonksiyonunu yitirmez. YSA'ların çok karmaşık problemlerin çözümündeki yüksek hesaplama yeteneği, hücrelerin bu yoğun ve paralel bağlantısı içerisinde çalışmasından kaynaklanmaktadır.

2.1 Yapay Sinir Ağlarının Genel Yapısı

Bir yapay sinir ağının temel elemanı nöronlar yani işlem birimleridir. Yapay sinir ağı işlem birimleri (elemanları) ile bağlantı geometrisinden oluşan eylem birimi ve bunlara ait bir graf biçimindedir. Her düğüm, hücre denilen n. dereceden doğrusal olmayan dinamik bir devredir.

YSA'ların elektrik devreleri bakımından tanımı, özet olarak aşağıdaki gibi sıralanabilir:

- YSA'larının düğümleri birer işlem elemanıdır.
- Düğümler arasındaki bağlantılar tek yönlü işaret iletim yollarıdır.
- Her işlem elemanı, istenildiği kadar girişe bağlanabilir.
- Her işlem elemanın tek bir çıkışı vardır. Fakat bu çıkışlar kopyalanabilir.
- İşlem elemanları yerel belleklere sahiptirler.
- Her işlem elemanının bir transfer (aktivasyon) fonksiyonu vardır. Bu fonksiyon, işlem elemanının çıkış değerini oluşturur. Transfer fonksiyonları sürekli veya ayrık olarak çalıştırılabilirler.
- YSA aynı transfer fonksiyonuna sahip alt gruplara ayrılabilir. Bunlara katman denir.
- Pek çok YSA giriş katmanı içerir ancak bu katmanın transfer fonksiyonu yoktur.

Yapay sinir ağlarında her işleme elemanının bir yerel belleği vardır. Bu bellekte, uyarılan katsayıların önceki hesaplamalar ile belirlenen değerleri saklanır. Her bir işleme elemanının çıkışı, son gelen giriş işaretlerinin ve yerel bellekteki adaptif katsayıların bir fonksiyonu olarak belirlenir. Bu fonksiyon transfer fonksiyonu olarak adlandırılır (Özyılmaz,2000).

Her işleme elemanı komşularında yapılan işlemlerden bağımsız olarak çalışır. Ancak bir işleme elemanının çıkışı diğer elemanlara da giriş olduğu için, tüm işleme elemanları bütün ağın davranışını gizli bir şekilde etkiler. İşleme elemanlarının arasındaki bağlantıların topolojisi, her işleme elemanının hangi bilgiyi aldığını ve dolayısıyla üzerinde çalışılabileceği bilgiyi belirlediği için, bir sinir ağının yürütebileceği tüm bilgi işleme fonksiyonlarını etkiler. (Hecht, 1991; Hertz vd. ,1991)

2.2 Yapay Sinir Ağı Modelleri

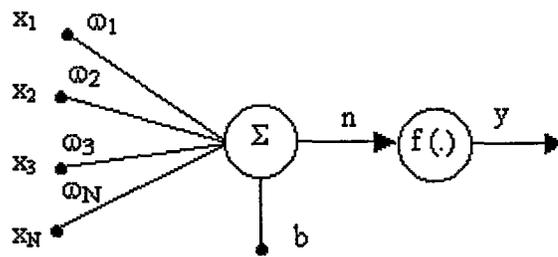
Yapay sinir ağları için geliştirilmiş ağlar temel olarak iki sınıfta değerlendirilirler: İleri beslemeli ağlar yada cebrik ağlar ve geri beslemeli ağlar yada dinamik ağlar. İleri beslemeli ağlar, örüntü tanıma (biomedikal işaret işleme, ses tanıma) problemlerinde, geri beslemeli ağlar ise optimizasyon (yol problemleri vb.) problemlerinin çözümünde başarılı olarak kullanılabilirler.

2.2.1 İleri Beslemeli Ağlar

İleri beslemeli ağlar, işaretin ağ girişinden çıkışına doğru tek yönlü olarak iletildiği ağlardır. Bir katmandaki hücreler, ancak bir önceki katmanın çıkışlarına giriş olabilir.

2.2.1.1 Hücre Modeli

İleri beslemeli ağlar, cebrik hücrelerden oluşur. Cebrik hücrelerde, Şekil 2.1’de görüldüğü gibi, standart modeldeki lineer dinamik sistem yoktur. Ayrıca girişlerin ve çıkışların geciktirilmişleri de bulunmaz.



Şekil 2.1 YSA hücre modeli

ω_i , x_i girişine ilişkin ağırlıktır. b ise sabit girişin ağırlığıdır ve eşik olarak adlandırılır. n

ağırlıklı toplam olmak üzere ifadesi şu şekilde yazılabilir:

$$n = \sum_{i=1}^N \omega_i x_i + b \quad (2.1)$$

Aşağıdaki tanımlar kullanılarak;

$$\omega = [\omega_1 \ \omega_2 \ \dots \ \omega_M]^T \quad (2.2)$$

$$x = [x_1 \ x_2 \ \dots \ x_M]^T \quad (2.3)$$

ağırlıklı toplayıcının ifadesi ve çıkış şu şekildi yazılabilir:

$$n = \omega^T x + b \quad (2.4)$$

$$y = f(n) \quad (2.5)$$

$f(\cdot)$ fonksiyonu olarak değişik fonksiyonlar kullanılmakta ve hücreler bu fonksiyonlara göre adlandırılmaktadır. En çok kullanılan sürekli fonksiyonlar: signum fonksiyonu, doymalı ve doymasız lineer fonksiyonlar, logaritmik ve tanjant sigmoid fonksiyonlarıdır.

2.2.1.2 Tek Katmanlı İleri Beslemeli Ağlar

Genelde tek bir hücre, istenen giriş-çıkış işlevini yerine getiremez. Bunun için bağlantı ağırlıkları dışında aynı özelliklere sahip hücreler bir araya getirilerek katmanlar oluşturulur. N girişli M çıkışlı tek katmanlı ileri beslemeli bir ağ Şekil 2.2'de gösterilmiştir.

Bir katmandaki tüm hücrelerin girişleri aynıdır. ω_{ji} , j. hücreye gelen i. girişin ağırlığı ve bu ağırlıklardan oluşan ω_j , i. hücrenin ağırlık vektörü olmak üzere şu şekilde tanımlanabilir:

$$\omega_j = [\omega_{j1} \ \omega_{j2} \ \dots \ \omega_{jN}]^T \quad (2.6)$$

b_j , j. hücrenin eşiği olmak üzere j. hücrenin ağırlıklı toplamı ve çıkışı,

$$n_j = \sum_{i=1}^M \omega_{ji} x_i + b_j \quad (2.7)$$

$$y_j = f(n_j) \quad (2.8)$$

olarak yazılabilir. Bu ifadeleri matris-vektör formunda yazmak için aşağıdaki tanımlamalar

yapılırsa;

$$\omega = [\omega_1 \ \omega_2 \ \dots \ \omega_N]^T \quad (2.9)$$

$$\mathbf{x} = [x_1 \ x_2 \ \dots \ x_N]^T \quad (2.10)$$

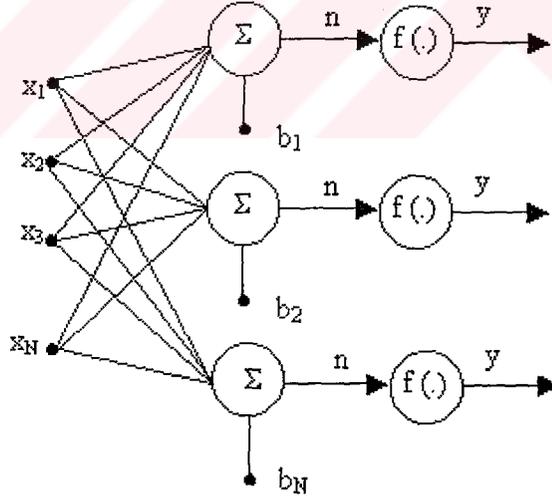
$$\mathbf{b} = [b_1 \ b_2 \ \dots \ b_N]^T \quad (2.11)$$

$$\beta = \begin{bmatrix} f(.) & 0 & \dots & 0 \\ 0 & f(.) & \dots & 0 \\ \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot \\ 0 & 0 & \dots & f(.) \end{bmatrix} \quad (2.12)$$

$$\mathbf{y} = [y_1 \ y_2 \ \dots \ y_N]^T \quad (2.13)$$

çıkış eşitliği şu şekilde yazılabilir:

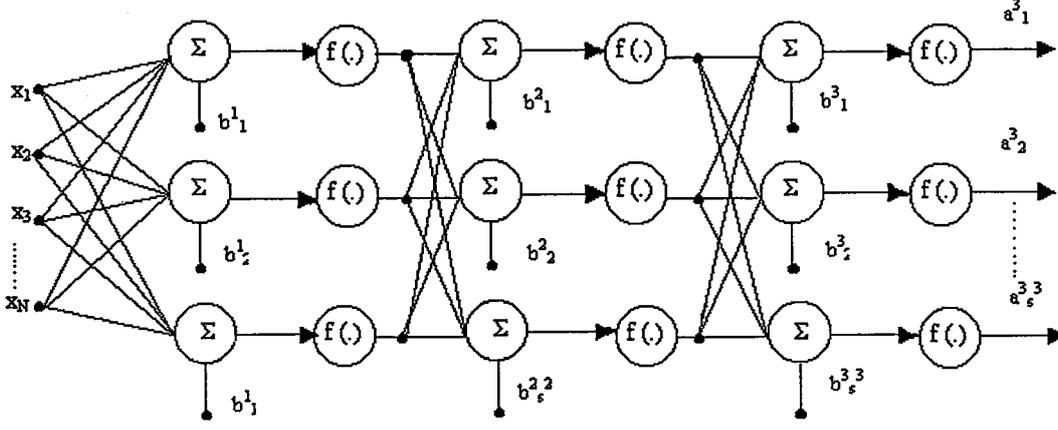
$$\mathbf{y} = \beta \left[\omega^T \mathbf{x} + \mathbf{b} \right] \quad (2.14)$$



Şekil 2.2 Tek katmanlı ileri beslemeli ağ

2.2.1.3 Çok Katmanlı İleri Beslemeli Ağlar

Katmanların kaskat bağlanmasından çok katmanlı ağlar oluşur. Bir katmanın girişi, bir önceki katmanın çıkışıdır. Şekil 2.3'te 3 katmanlı ileri beslemeli bir ağ verilmiştir.



Şekil 2.3 Çok katmanlı YSA mimarisi

Giriş katmanı, sadece girişi çoğullamaktadır yani girişleri ile çıkışları aynıdır. Giriş katmanı ile çıkış katmanı arasında kalan katmanlara gizli katmanlar adı verilmektedir. Genelde bir veya iki gizli katman kullanmak yeterli olmaktadır. Toplam katman sayısı verilirken giriş katmanı, dahil edilmez. Gizli katmanlardaki hücre sayıları farklı olabilir.

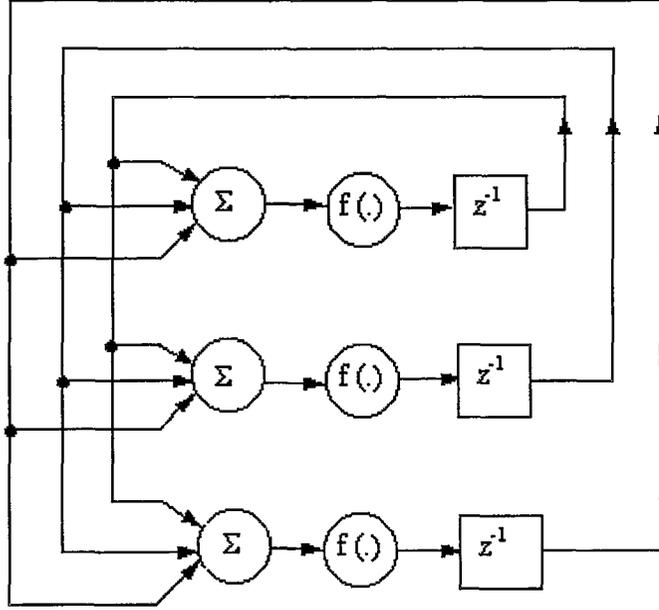
ω^i , i. katmanın ağırlık matrisi, b^i , i. katmanın eşik vektörü ve β^i [.] , i. katmanın matris operatörü olmak üzere üç katmanlı bir ağırlık çıkışı şu şekilde yazılır:

$$y = \beta^3 [\omega^3 \beta^2 [\omega^2 \beta^1 [\omega^1 x + b^1] + b^2] + b^3] \quad (2.15)$$

2.2.2 Geri Beslemeli Ağlar

Geri beslemeli ağlarda, bir katmandaki hücreler, sadece bir önceki katmanın çıkışlarını değil aynı zamanda veya daha sonraki katmanlarında çıkışlarını giriş olarak alabilirler. Bu yüzden çıkış, sadece o anki girişlere değil, başlangıç durumuna ve daha önceki girişlere de bağlıdır (Şekil 2.4).

Geri beslemeli ağ modellerinin çoğunda, kullanılan hücrelerde, ağırlıklı toplayıcı ile çıkış fonksiyonu arasında cebrik hücrelerde bulunmayan ancak standart hücre modelinde verilen tek girişli-tek çıkışlı lineer bir sistem vardır. Dinamik ağlardan en çok bilinenleri, Hopfield Ağı, Hücresel Yapay Sinir Ağı, Grossberg Ağı, ART1 ve ART2 ağlarıdır.



Şekil 2.4 Geri beslemeli ağ mimarisi

2.3 Yapay Sinir Ağlarında Öğrenme

Öğrenme kuralı, giriş işaretleri ve aktivasyon fonksiyonu tarafından sağlanan değerlere cevap olarak yerel bellekteki ağırlıkların hepsini veya bazılarını değiştiren eşitliktir. Ağırlıkların değişimi giriş işaretlerinin doğasına bağlı olarak, işleme elemanının cevabının değişmesini sağlar. Ağ kendisini istenen cevaplara göre ayarlayabilir ve kendi içinde bilgiyi düzenleyebilir yani kısaca öğrenebilir. Bu şekildeki ağırlıkların ayarlanmasına öğrenme kuralı denir.

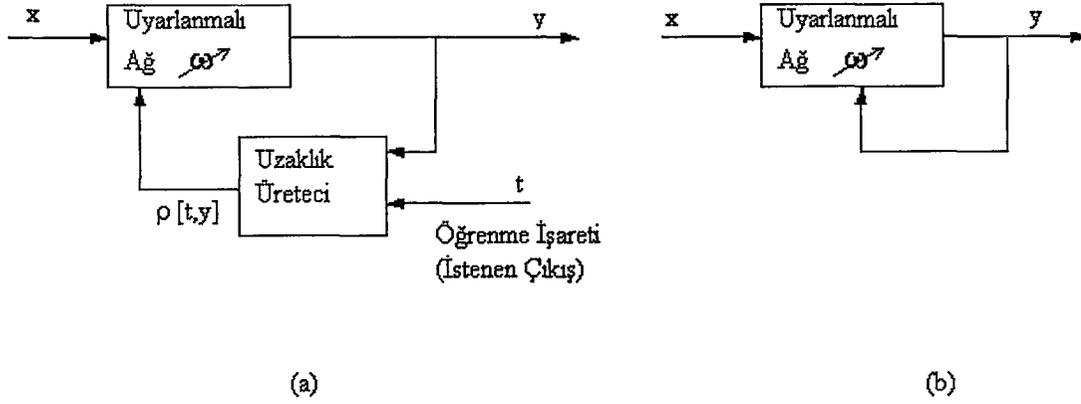
Öğrenmesi istenen ilişki çok değişkenli $h(x)$ fonksiyonu ile verilmiş ise bu fonksiyon başka $H(\omega, x)$ fonksiyonu tarafından yaklaşık olarak ifade edilebilir. Burada x , giriş ve ω , ağırlık vektörüdür. YSA için öğrenme işlemi de eğitime örnekleri kümesi $\{x\}$ 'e dayalı olarak $h(x)$ 'e mümkün en iyi yaklaşımı sağlayan ω^* 'ı bulmaktadır.

$H(\omega, x)$ fonksiyonunun seçimi, $h(x)$ 'i temsil etme probleminde önemli bir seçimdir. $H(\omega, x)$ seçildikten sonra öğrenme algoritmaları yardımıyla optimal bir ω parametreleri bulunabilir. Daha kesin bir ifadeyle her ω için

$$\rho[H(\omega^*, x), h(x)] \leq \rho[H(\omega, x), h(x)] \quad (2.16)$$

ifadesini sağlayan ω^* 'ı bulma problemi olarak ifade edilebilir. Burada $\rho(\cdot)$ uzaklık fonksiyonu yada $H(\omega, x)$ ile $h(x)$ arasındaki yaklaşım kalitesini veren fonksiyondur.

Öğrenme giriş çıkış hakkında bilgi olmaması veya tam olmayan ön bilgiye sahip olması durumunda gerekli olmaktadır. Öğrenme sistemleri de sahip olunan bilgiye göre farklı şekillerde geliştirilmiş, eğitici ve eğitici-siz diye iki gruba ayrılmıştır. Bu öğrenme algoritmalarının blok şemaları Şekil 2.5’de görülmektedir.



Şekil 2.5 (a) Eğitici (b) Eğitici-siz öğrenme algoritmaları blok şemaları

2.3.1 Eğitici Öğrenme

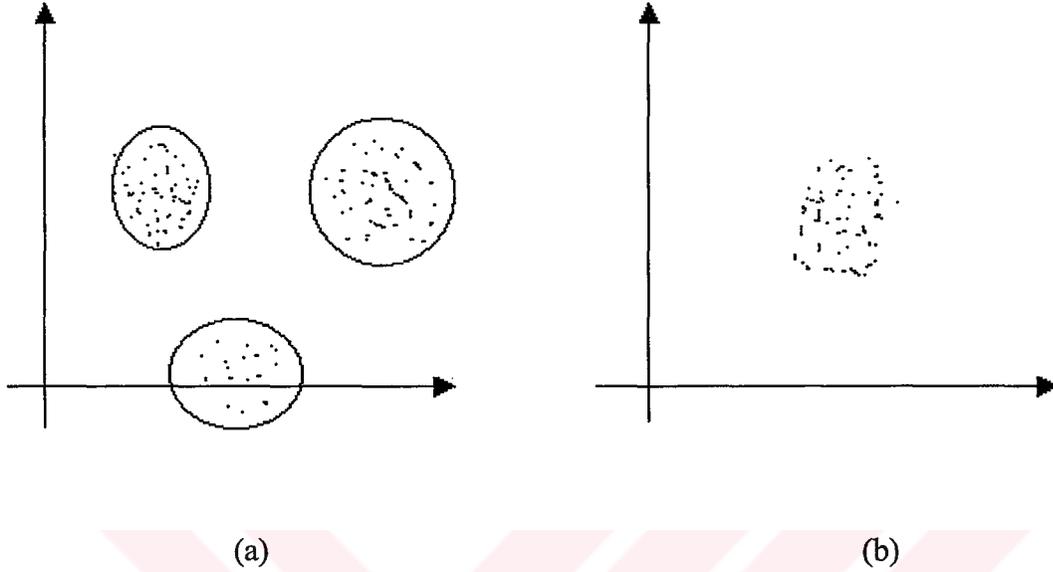
Girişin uygulandığı her bir anda sistemin vermesi istenen cevap “t”, eğitici tarafından sağlanır. Gerçek ve istenen çıkış arasındaki uzaklık $\rho[t,y]$, ağ parametrelerini düzeltmek maksadı ile kullanılan hata mesajı ölçüsü olarak görev yapar. Ağırlıklar ayarlanabilir kabul edildiğinden, ω 'yı düzeltmek için bir ödül-ceza tablosu oluşturulur. Örneğin giriş örneklerinin sınıflandırılmasının öğrenilmesinde, hata işareti ağırlıkları, hata azaltacak şekilde değiştirir. Yaygın olan bu öğrenme şeklinde, giriş-çıkışlardan oluşturulmuş bir eğitim kümesi gereklidir. Eğitici, negatif hata eğitim yönünü tahmin ederek hatayı azaltır.

2.3.2 Eğitici-siz Öğrenme

Bu öğrenme durumunda istenen çıkış bilinmemektedir ve böylelikle ağın davranışını iyileştirmede dışardan bir hata bilgisi kullanılamaz.. Örneğin, eğitici-siz öğrenme Şekil 2.6’daki gibi dağılan giriş vektörlerinin sınıfları arasındaki sınırları bulmada sonuç verebilir.

Bu tip öğrenmede ağ, varolan örnekler, düzenlilikler ve ayırıcı özellikleri kendisi keşfetmek durumundadır. Bunu yaparken de kendi kendini düzenleme (self organizing) olarak

adlandırılan parametrelerini deęiřtirme yoluna gider. Fakat genellikle, eęitici ortamda öğrenme mümkün olamamaktadır. Örneęin Őekil 2.6.(b)'de görölen durumda örnek sınıfları ayırmak imkansıza yakındır.



Őekil 2.6 İki boyutlu uzayda giriş örnekleri: (a) Kümelenmiş (b) Belirli kümeler yok (Genç,1996)

2.4 Öğrenme Kuralları

Yapay sinir ağlarının, istenen giriş çıkış ilişkilerini, aęrlıkları deęiřtirmeyle öğrendięi yukarıda belirtilmiřti. Bu aęrlıklar, öğrenme kuralları ile deęiřtirilir. Deęiřik aę modelleri için farklı öğrenme kuralları geliřtirilmiřtir.

j . hücrenin aęrlık vektörü ω_j , $\omega_j(0)$ bařlangıç deęerinden bařlanarak ardıřıl olarak deęiřtirilir. $(k+1)$. adım için ω_j aęrlık vektörü řu řekilde hesaplanır:

$$\omega_j(k+1) = \omega_j(k) + \Delta\omega_j(k) \quad (2.17)$$

$\Delta\omega_j$, aęrlık deęiřimi, x giriş vektörü ile öğrenme iřareti r 'nin çarpımıyla orantılıdır. Öğrenme iřareti r , genel olarak ω_j , x ve eęitici öğrenmede eęitici iřareti (istenen çıkıř) t_j 'nin bir fonksiyonudur. Buna göre k . adım için $\Delta\omega_j(k)$ řu řekilde yazılabilir:

$$\Delta\omega_j(k) = \alpha r [\omega_j(k), x(k), t_j(k)] x(k) \quad (2.18)$$

Burada α , öğrenme oranı olarak adlandırılan ve öğrenmenin hızını belirleyen pozitif bir

sayıdır. Eşik, sabit girişin ağırlığı olduğu için benzer şekilde,

$$b_j(k+1) = b_j(k) + \Delta b_j(k) \quad (2.19)$$

$$\Delta b_j(k) = \alpha r_b[b_j(k), t] \quad (2.20)$$

olarak yazılabilir. Tek katmanlı ileri beslemeli ağlar için eğitici öğrenme kuralları, Algılayıcı Öğrenme Kuralı, Delta Öğrenme Kuralı, Widrow-Hoff Öğrenme Kuralı ve eğitici öğrenme kuralları, Hebb Öğrenme Kuralı ve Kazanan-Hepsini-Alır Öğrenme Kuralı, çok katmanlı ileri beslemeli ağlar için eğitici öğrenme kuralı olarak da Geriye Yayılım Algoritması verilebilir. (Özyılmaz, 2000)

Geriye yayılım algoritması, günümüzde en çok kullanılan öğrenme algoritmasıdır. Bunda öğrenme kapasitesi ve algoritmanın basitliği etkili olmaktadır.

Geriye yayılım algoritması, gerçek çıkış (ağın çıkışı) a ile hedeflenen çıkış t arasındaki ortalama karesel hatayı minimum yapmak için adımsal düşüm (steepest descent) algoritmasını kullanır.

Eğitim kümesi :

$$\{x_1, t_1\}, \{x_2, t_2\}, \dots, \{x_Q, t_Q\} \quad (2.21)$$

değerlerinden oluşur. x_q giriş değerleri ve t_q , girişlere karşılık düşen hedeflerdir. Girişe uygulanan her bir x değerine karşılık düşen hedef çıkış arasında karşılaştırma yapılır. Algoritma, ortalama karesel hatayı minimum yapacak şekilde ağ parametrelerini ayarlar. Ağın hata fonksiyonu ifadesi,

$$F(p) = E[e^2] = E[(t-a)^2] \quad (2.22)$$

eşitliği ile gösterilir. p , ağın ağırlık ve eşiklerinin vektörüdür. Ağ çoklu çıkışa sahip ise,

$$F(p) = E[e^T e] = E[(t-a)^T (t-a)] \quad (2.23)$$

yazılabilir. k . iterasyon için ,

$$\hat{F}(p) = (t(k) - a(k))^T (t(k) - a(k)) = e^T(k) e(k) \quad (2.24)$$

bağıntısı ifade edilir. Adımsal düşüm algoritması ile yeni ağırlık ve eşik değerleri,

$$\omega_{i,j}^m(k+1) = \omega_{i,j}^m(k) - \alpha \cdot \frac{\partial \hat{F}}{\partial (\omega_{i,j}^m)} \quad (2.25)$$

$$b_i^m(k+1) = b_i^m(k) - \alpha \cdot \frac{\partial \hat{F}}{\partial (b_i^m)} \quad (2.26)$$

şeklinde elde edilir. Bu ifadelerdeki α , öğrenme oranıdır.

Gizli katmanların ağırlık değerlerinden dolayı eşitlik (2.25) ve eşitlik (2.26)'daki hata fonksiyonunun kısmi türevlerinin hesaplanmasında zincir kuralı kullanılır:

$$\frac{\partial \hat{F}}{\partial \omega_{i,j}^m} = \frac{\partial \hat{F}}{\partial n_i^m} \frac{\partial n_i^m}{\partial \omega_{i,j}^m} \quad (2.27)$$

$$\frac{\partial \hat{F}}{\partial b_i^m} = \frac{\partial \hat{F}}{\partial n_i^m} \frac{\partial n_i^m}{\partial b_i^m} \quad (2.28)$$

m. katmana giren toplam giriş değerleri ağırlık ve eşik değerlerinin fonksiyonu olduğundan dolayı bu eşitliklerdeki ikinci terimler kolaylıkla hesaplanabilir:

$$n_i^m = \sum_{j=1}^{s^{m-1}} \omega_{i,j}^m a_j^{m-1} + b_i^m \quad (2.29)$$

$$\frac{\partial n_i^m}{\partial \omega_{i,j}^m} = a_j^{m-1}, \quad \frac{\partial n_i^m}{\partial b_i^m} = 1 \quad (2.30)$$

Bu eşitliklerden yararlanarak m'inci katmandaki \hat{F} 'in, ağırlık i. giriş elemanının değişimine olan duyarlılığı:

$$s_i^m \equiv \frac{\partial \hat{F}}{\partial n_i^m} \quad (2.31)$$

şeklinde ifade edilir. (2.27) ve (2.28) eşitlikleri kullanılarak,

$$\frac{\partial \hat{F}}{\partial \omega_{i,j}^m} = s_i^m a_j^{m-1} \quad (2.32)$$

$$\frac{\partial \hat{F}}{\partial b_i^m} = s_i^m \quad (2.33)$$

sonuçları bulunur. Bu eşitlikler ışığında adımsal düşüm algoritmasının ifadesi aşağıdaki gibi yazılabilir,

$$\omega_{i,j}^m(k+1) = \omega_{i,j}^m(k) - \alpha s_i^m a_j^{m-1} \quad (2.34)$$

$$b_i^m(k+1) = b_i^m(k) - \alpha \cdot s_i^m \quad (2.35)$$

Matris formda yazılacak olursa,

$$W^m(k+1) = W^m(k) - \alpha s^m (a^{m-1})^T \quad (2.36)$$

$$B^m(k+1) = B^m(k) - \alpha \cdot s^m \quad (2.37)$$

$$s^m \equiv \frac{\partial \hat{F}}{\partial n^m} = \begin{bmatrix} \frac{\partial \hat{F}}{\partial n_1^m} \\ \frac{\partial \hat{F}}{\partial n_2^m} \\ \cdot \\ \cdot \\ \cdot \\ \frac{\partial \hat{F}}{\partial n_{s^m}^m} \end{bmatrix} \quad (2.38)$$

ifadeleri elde edilir. s^m , duyarlılık ifadesinin hesaplanması için zincir kuralı kullanılmalıdır. m 'inci katmanın duyarlılığı $(m+1)$ katmanının duyarlılığı kullanılarak hesaplanır. Geriye yayılım terimi buradan gelmektedir.

Duyarlılıkların ardışıl ilişkilerini ortaya çıkarmak için aşağıdaki Jacobian matrisi kullanılır:

$$\frac{\partial \mathbf{n}^{m+1}}{\partial \mathbf{n}^m} \equiv \begin{bmatrix} \frac{\partial n_1^{m+1}}{\partial n_1^m} & \frac{\partial n_1^{m+1}}{\partial n_2^m} & \dots & \frac{\partial n_1^{m+1}}{\partial n_{s^m}^m} \\ \frac{\partial n_2^{m+1}}{\partial n_1^m} & \frac{\partial n_2^{m+1}}{\partial n_2^m} & \dots & \frac{\partial n_2^{m+1}}{\partial n_{s^m}^m} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial n_{s^{m+1}}^{m+1}}{\partial n_1^m} & \frac{\partial n_{s^{m+1}}^{m+1}}{\partial n_2^m} & \dots & \frac{\partial n_{s^{m+1}}^{m+1}}{\partial n_{s^m}^m} \end{bmatrix} \quad (2.39)$$

$$\frac{\partial n_i^{m+1}}{\partial n_j^m} = \frac{\partial \left(\sum_{k=1}^{s^m} \omega_{i,k}^{m+1} a_k^m + b_i^m \right)}{\partial n_j^m} = \omega_{i,j}^{m+1} \frac{\partial a_j^m}{\partial n_j^m} \quad (2.40)$$

$$= \omega_{i,j}^{m+1} \frac{\partial f^m(n_j^m)}{\partial n_j^m} = \omega_{i,j}^{m+1} f^m(n_j^m) \quad (2.41)$$

$$f^m(n_j^m) = \frac{\partial f^m(n_j^m)}{\partial n_j^m} \quad (2.42)$$

Bu eşitlikler ışığında Jacobian matris şu şekilde yazılabilir,

$$\frac{\partial \mathbf{n}^{m+1}}{\partial \mathbf{n}^m} = \mathbf{W}^{m+1} \mathbf{F}^m(\mathbf{n}^m) \quad (2.43)$$

$$\mathbf{F}^m(\mathbf{n}^m) = \begin{bmatrix} f^m(n_1^m) & 0 & \dots & 0 \\ 0 & f^m(n_2^m) & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & f^m(n_{s^m}^m) \end{bmatrix} \quad (2.44)$$

Matris formda zincir kuralı yazılarak,

$$s^m = \frac{\partial \hat{F}}{\partial n^m} = \left(\frac{\partial n^{m+1}}{\partial n^m} \right) \frac{\partial \hat{F}}{\partial n^{m+1}} = F^m (n^m) (W^{m+1})^T \frac{\partial \hat{F}}{\partial n^{m+1}} \quad (2.45)$$

$$= F^m (n^m) (W^{m+1})^T s^{m+1} \quad (2.46)$$

bağıntıları elde edilir. Geriye yayılım algoritmasında duyarlılık son katmandan ilk katmana doğru ilerler:

$$s^M \rightarrow s^{M-1} \rightarrow \dots \rightarrow s^2 \rightarrow s^1 \quad (2.47)$$

Algoritmanın çalışması esnasında eğimin hesaplanması için ilk geriye yayılım duyarlılığının bilinmesi gerekmektedir. Bu nedenle başlangıç noktası için s^M , (2.46) eşitliği kullanılarak,

$$s_i^M = \frac{\partial \hat{F}}{\partial n_i^M} = \frac{\partial (t-a)^T (t-a)}{\partial n_i^M} = \frac{\partial \sum_{j=1}^{s^M} (t_j - a_j)^2}{\partial n_i^M} = -2 (t_i - a_i) \frac{\partial a_i}{\partial n_i^M} \quad (2.48)$$

$$\frac{\partial a_i}{\partial n_i^M} = \frac{\partial a_i^M}{\partial n_i^M} = \frac{\partial f^M (n_j^M)}{\partial n_i^M} = f^M (n_j^M) \quad (2.49)$$

$$s_i^M = -2 (t_i - a_i) f^M (n_j^M) \quad (2.50)$$

elde edilir. Matris formda aşağıdaki ifade kullanılır,

$$s^M = -2 F^M (n^M) (t - a) \quad (2.51)$$

Sonuç olarak, ağıın ileri yönde yayılımı durumunda,

$$a^0 = x \quad (2.52)$$

$$a^{m+1} = f^{m+1} (W^{m+1} a^m + b^{m+1}), \quad m=0,1,2,\dots,M-1 \quad (2.53)$$

$$a = a^M \quad (2.54)$$

eşitlikleri geçerlidir. Geriye yayılım durumunda ise,

$$s^M = -2 F^M (n^M)(t - a) \quad (2.55)$$

$$s^m = F^m (n^m) (W^{m+1})^T s^{m+1}, \quad m = M-1, \dots, 2, 1 \quad (2.56)$$

eşitlikleri kullanılır. Bu yayılım sonucunda elde edilen yeni ağırlık ve eşik değerleri şu şekilde ifade edilir (Hagan vd.,1996):

$$W^m(k+1) = W^m(k) - \alpha s^m (a^{m-1})^T \quad (2.57)$$

$$B^m(k+1) = B^m(k) - \alpha .s^m \quad (2.58)$$

2.5 Öğrenme Faktörleri

Geriye yayılım algoritması, eğitimin yavaş olması, algoritmanın yerel minimuma yakalanabilmesi gibi dezavantajlara sahiptir. Geriye yayılım algoritmasında, ardarda iki katmandaki n tane birim için, n^2 tane ağırlık eğitilmektedir. Hatanın geriye yayılımı da bu ağırlıklar üzerinden yapılır. Bu işlemler oldukça zaman alır. Eğitim zamanını etkileyen faktörler ise ilk ağırlıklar, öğrenme oranı, gizli katman sayısı ve gizli katmandaki hücre sayısıdır. Hatayı minimum yapacak ağ ağırlıkları, bir gradyent arama tekniği kullanılarak bulunur. Eğitime sırasında yerel minimuma yakalanma sorunu vardır. Bu durumda ağ kabul edilemeyecek bir çözüme yakınsar. Bu sorundan kaçınmak için öğrenme oranı azaltılabilir. Ağa yeni bilgiler öğretildiğinde eskiden öğrenilen bilgilerin unutulması nedeniyle; ağ, değişen çevre şartlarına uyum sağlanmasının beklendiği durumlar için uygun değildir.

2.5.1 Yakınsama

$E=E(\omega)$ hata fonksiyonu, $\omega \in R^q$ ağın tüm ağırlıklarını içeren bir vektör olmak üzere $q+1$ boyutlu uzayda bir yüzey tanımlar. $E(\omega)$ 'nın tek global minimumu ve birçok yerel minimumu olabilir. Pratikte çok katmanlı ağların, eğitim sırasında yerel minimuma takılması durumu ile ender olarak karşılaşılmaktadır. Eğer bir yerel minimuma ulaşırsa, eğitim, birkaç yeni hücre ekleyerek yine rastgele ağırlıklardan başlatılmalı yada yerel minimum, sığ ise ağırlıklara rastgelelik eklenmelidir. İdeal durumda hatanın sıfır olması veya sıfırdan büyük bir global minimuma ulaşılması beklenir. Ancak bu, pratikte sonsuz zaman gerektirebilir. Bunun yerine öğrenmenin kabul edilebilir bir E_{\max} değerinin altındaki hatalar için başarılı olduğu kabul edilir.

2.5.2 İlk Ağırlıklar

Eğitimin başlaması aşamasında başlangıç ağırlıklarının seçimi, ağıın sonuca yakınsaması açısından çok önemlidir. Başlangıçta, eğitilecek ağıın ağırlıkları, küçük, rastgele olarak seçilir. Eğer büyük değerlerde seçilirse ağıırlıklı toplam da büyük değerler alır. Ancak çıkış fonksiyonunun bu noktadaki türevi çok küçük olur. Ağıırlık deęişiminde de bu türev çarpım olarak geldięi için, her adımda çok küçük deęişimler olacaktır. Bu da eğitim zamanını çok artıracaktır. Aynı sebepten dolayı girişlerde küçük değerlerde alınır. Genelde ağıırlıklar $[-1, +1]$ aralığında seçilir. Girişler ise $[-1, +1]$ aralığına ötelenerek kullanılır veya normalize edilir.

2.5.3 Öğrenme Oranı

Geriye yayılma algoritmasının sonuca yakınsamasında öğrenme oranı önemlidir. Genel olarak, öğrenme oranının en iyi değeri çözülecek probleme baęlıdır. Teknik literatürde, deęişik problemler için $[0,1]$ aralığındaki öğrenme oranı değeriinin başarıyla uygulanabildiğini gösteren çalışmalar vardır. Büyük öğrenme oranı değeri, hata yüzeyinde büyük adımlar atılmasını sağlasa da ağıın kararsız olmasına veya osilasyon yapmasına sebep olabilir. Bu da ağıın bir minimuma yakınsamasına engel olabilir. Küçük değeri ise, bu problemi gidermesine rağmen eğitimin çok uzamasına sebep olur.

3. DALGACIK TEORİSİ

Dalgacık teorisi esas olarak dalgacık fonksiyonları ile bu fonksiyonların kullanımı sonucu gerçekleştirilen dönüştürme yöntemlerini içerir. Dalgacık dönüşümü, temel olarak “Ana Dalgacık” olarak adlandırılan fonksiyonun öteleme ve ölçekleme parametreleri ile birlikte formülize edilmiş şeklidir. Zaman eksenli ayrıştırma, geçici özelliklere sahip işaret bileşenlerinin analizinde büyük fayda sağlamaktadır (Muret ve Omid,1995). Analiz sonucu işaretlerin çok önemli özelliklerinin çıkarılması veya daha az veri ile ifade edilebilmeleri mümkün olabilmektedir. Son zamanlarda bu özelliği ile dalgacık dönüşümü, işaret ön işleme birimi olarak özellikle yapay sinir ağları ile birlikte kullanılmaktadır.

Dalgacık dönüşümü ile Fourier dönüşümü arasındaki en önemli fark zaman bilgisinin varlığıdır. Fourier dönüşümü ile frekans domenine geçişte zaman bilgisinin kayıp olması ciddi bir dezavantajdır. İşaretin Fourier dönüşümüne bakarak bir bilginin frekansının ne zaman ortaya çıktığı söylenemez. Eğer işaret çoğu zaman değişmiyorsa (durağan) bu dezavantaj önemli değildir. Bununla beraber bazı işaretler birçok durağan olmayan bileşenler veya geçiş karakteristikleri (yığılma, ani değişiklikler, olayların başlaması veya bitmesi vb..) içerirler. Bu karakteristikler çoğunlukla da işaretlerin önemli parçalarıdır. Dalgacık dönüşümü ile bu tür değişimlerin tespiti değişken-boyutlu bölgeler ve pencereleme teknikleri kullanılarak mümkün olabilmektedir.

Bu bölümde dalgacık fonksiyonları, sürekli ve ayrık dalgacık dönüşümleri incelenerek, işaret analizi ve özellik çıkarımında sağlamış oldukları kolaylıklar incelenecektir.

3.1 Dalgacık Fonksiyonları

Fourier dönüşümünde kullanılan temel fonksiyonlar sinüs ve kosinüs fonksiyonlarıdır. Analiz edilen işaretler bu fonksiyonların değişik genlik ve frekans değerlerinin sentezi ile ifade edilirler. Dalgacık dönüşümünde ise temel fonksiyonlar çok çeşitlidir ve bu fonksiyonlara dalgacık fonksiyonları adı verilir.

Birçok dalgacık fonksiyon ailesi arasında Haar dalgacığı ilk akla gelen en basit dalgacıktır. Ölçekleme ile dalgacık fonksiyonları basit karesel dalgalardır ve şu şekilde tanımlanırlar,

$$\phi(x) = \begin{cases} 1 & 0 < x < 1 \\ 0 & \text{diğer} \end{cases} \quad \text{ve} \quad \psi(x) = \begin{cases} 1 & 0 \leq x < 1/2 \\ -1 & 1/2 \leq x < 1 \\ 0 & \text{diğer} \end{cases} \quad (3.1)$$

Haar dalgacıkları ortogonaldır ve ortogonal genişleme dalgacıklarından oluşmuştur.

Sürekli-zaman fonksiyonu $\psi(t)$ 'nin gerçel ve kompleks değerleri şu özellikleri ile birlikte değerlendirilir (Daubechies 1988; Grossman ve Morlet 1984):

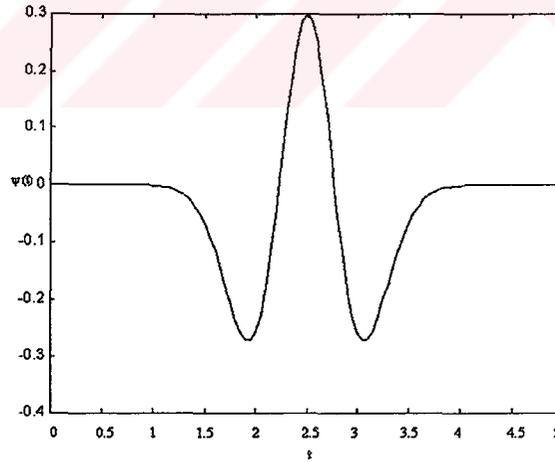
Fonksiyonun integrali sıfıra eşittir:

$$\int_{-\infty}^{\infty} \psi(t) dt = 0 \quad (3.2)$$

Sınırlı enerjiye sahiptir:

$$\int_{-\infty}^{\infty} |\psi(t)|^2 dt < \infty \quad (3.3)$$

Bu iki özelliği sağlayan $\psi(t)$ fonksiyonu ana dalgacık veya dalgacık fonksiyonu olarak adlandırılır. Özellik-1 fonksiyonun salınımına sahip olduğunu gösterir. Özellik-2 ise $\psi(t)$ 'nin enerjisinin sınırlı zaman aralığı içinde olduğunu gösterir. Bu salınım sinüs biçiminden daha küçük dalgalardır (dalgacıklar).



Şekil 3.1 Kübik B-spline dalgacık

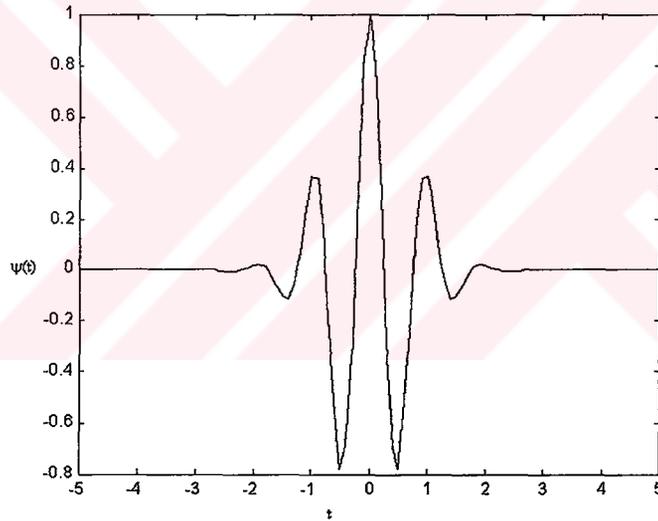
Şekil 3.1'de "Kübik B-spline" olarak adlandırılan dalgacık fonksiyonu görünmektedir. Bu dalgacık sınırlı uzunluğa sahip ($1 \leq t \leq 4$) küçük bir dalga şeklindedir.

Bununla beraber benzer şekilde sınırlı alana sahip olmayan Morlet dalgacığı gibi fonksiyonlar da vardır. Morlet, sinüs fonksiyonunun Gauss fonksiyonu ile module edilmesinde

oluşturulmuştur (Şekil 3.2) (Daubechies 1990; Vetterli ve Kovacevic 1995). Bu dalgacık sınırsız zamana sahip olmasına rağmen enerjisi sınırlı aralıkta kalmaktadır. Gerçek değerli Morlet dalgacığı şu şekilde ifade edilir:

$$\psi(t) = e^{-t^2} \cos\left(\pi \sqrt{\frac{2}{\ln 2}} t\right) \quad (3.4)$$

Fonksiyonun enerjisinin %99'dan fazlası $|t| \leq 2.5$ s aralığında bulunmaktadır. Morlet dalgacıkları ölçekleme ve frekans arasındaki ilişkiden dolayı oldukça popülerdir. Simetrik olması ve tam bir zaman-frekans analizi sağlaması açısından Morlet dalgacıkları oldukça kullanışlıdır. Bunun yanında, ölçekleme fonksiyonu ϕ 'nin olmaması ve ortogonal olmamasından dolayı hızlı algoritmalarla hesaplanamaması gibi dezavantajlara sahiptir. Diğer dezavantaj da, ters dalgacık dönüşümünde tam bir yeniden yapılanmanın olmayışıdır (Bentley ve Grant, 1995).



Şekil 3.2 Morlet Dalgacığı

Bu dalgacık fonksiyonlarının yanında Meksika Şapkası, iki tümsekli dalgacıklar, Meyer Dalgacıkları, Battle-Lemarie dalgacıkları da vardır. Bu dalgacıklar da birbirlerine göre avantaj ve dezavantajlara sahiptirler. Uygun kullanım alanı veya amacına göre başarılı sonuçlar alınabilmektedir.

3.2 Dalgacık Dönüşümü

Kısa-zaman Fourier dönüşümünde (KZFD) durağan olmayan işaret, zamanda durağan kabul edilebilecek küçük parçalara bölünür. Fourier dönüşümünden (FD) farklı olarak, işarete dar

pencerelerden bakılır ve pencere içinde kalan işaretin durağan olduğu varsayılır. Aşağıda KZFD'nin ifadesi görülmektedir:

$$KZFD(\tau, f) = \int \left[x(t) \cdot w^*(t - \tau) \right] e^{-j2\pi ft} dt \quad (3.5)$$

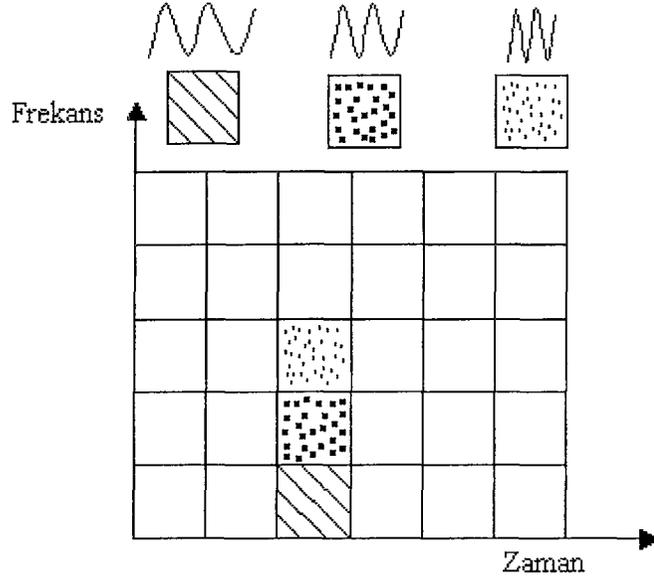
$x(t)$, orjinal işareti; $w(t)$, pencere fonksiyonunu ve $*$, kompleks konjugeyi göstermektedir. f , frekans; τ ise zamanda öteleme miktarıdır. Eşitlikte görüldüğü gibi KZFD, bir pencere fonksiyonu ile çarpılan $x(t)$ 'nin FD'den oluşmaktadır. Her τ ve f için yeni bir KZFD katsayısı hesaplanır. FD, sadece frekansın bir fonksiyonu iken, KZFD hem frekansın hem de zamanın bir fonksiyonudur ve dönüşüm bu haliyle iki boyutludur.

İşaretin zaman-frekans dönüşümü elde edilmesine rağmen, seçilen pencerenin genişliği dönüşümün etkinliğinde önemli rol oynamaktadır. KZFD'de pencere genişliği ile ilişkili bir çözünürlük problemi bulunmaktadır.

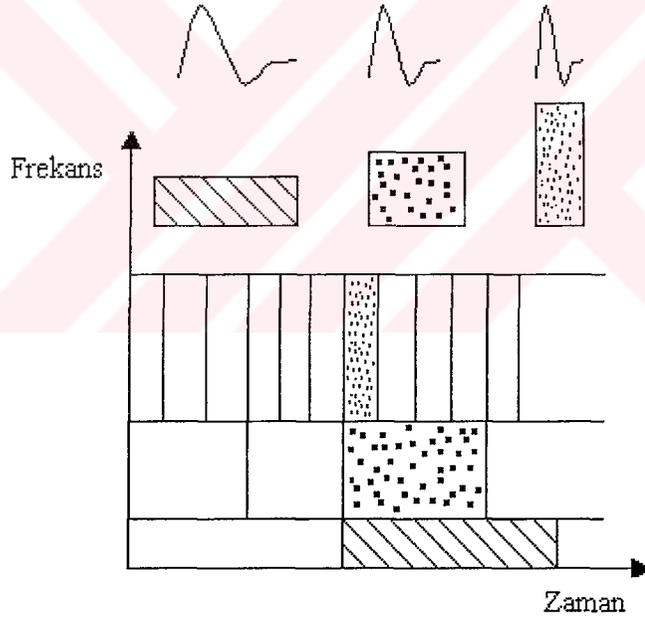
Pencere genişliği durağanlık varsayımını geçerli kılacak kadar dar olmalıdır. Dar bir pencere seçilmesi durumunda hem bu varsayım geçerliliğini koruyacak hem de FD'de sağlanamayan zamanda çözünürlük iyileşecektir. Fakat dar bir pencere seçilmesi durumunda kötü bir frekans çözünürlüğü elde edilir. Pencere genişledikçe frekans çözünürlüğü artar; ancak zamanda çözünürlük azalır. Sonuçta işarete KZFD'yi uygulamadan önce bir ikileme karşılaşılr: Zamanda ya da frekansta çözünürlüğün sağlanması.

KZFD, tüm zamanlarda sabit çözünürlük verdiği için bu problemi gidermek üzere zamanda değişken çözünürlük veren dalgacık dönüşümü geliştirilmiştir (Şekil 3.3). Dalgacık dönüşümüne, frekans spektrumu zamanla değişen durağan olmayan işaretlerin analizinde ihtiyaç duyulmaktadır.

Dalgacık analizi KZFD'ye benzer şekilde yapılır: İşaret, KZFD'de bir pencere fonksiyonu ile çarpılırken, dalgacık dönüşümünde dalgacık olarak adlandırılan bir fonksiyonla çarpılır. Dalgacık dönüşümü sürekli ve ayrık olmak üzere ikiye ayrılır (Dokur,1999).



(a) Kısa Zamanlı Fourier dönüşümü



(b) Dalgacık dönüşümü

Şekil 3.3 Kısa Zamanlı Fourier ve dalgacık dönüşümünün zaman - frekans hücreleri

3.2.1 Sürekli Dalgacık Dönüşümü

$f(t)$ karesel integrali alınabilir fonksiyon olmak üzere, $f(t)$ 'nin sürekli dalgacık dönüşümü (SDD) şu şekilde tanımlanmıştır (Grossman ve Morlet 1984; Daubechies 1992) :

$$W(a, b) = \int_{-\infty}^{\infty} f(t) \psi^* \left(\frac{t-b}{a} \right) dt \quad (3.6)$$

$f(t)$: analiz edilen işaret

W : Dalgacık dönüşümü

ψ^* : analiz dalgacığı ψ 'nin karmaşık eşleniği

a : ölçekleme parametresi

b : öteleme parametresi

$f(t)$ ve $\psi(t)$ fonksiyonları $L^2(\mathbb{R})$ uzayına aittir ve karesel integrali alınabilir fonksiyonlar olduklarından dolayı enerji fonksiyonları olarak adlandırılırlar.

$\psi_{a,b}(t)$ ifadesi şu şekilde tanımlanır:

$$\psi_{a,b}(t) = \frac{1}{\sqrt{|a|}} \psi \left(\frac{t-b}{a} \right) \quad (3.7)$$

(3.6) ve (3.7) eşitliklerini birleştirerek:

$$W(a, b) = \int_{-\infty}^{\infty} f(t) \psi_{a,b}^*(t) dt \quad (3.8)$$

ifadesi elde edilir. Dikkat edilirse,

$$\psi_{1,0}(t) = \psi(t) \quad (3.9)$$

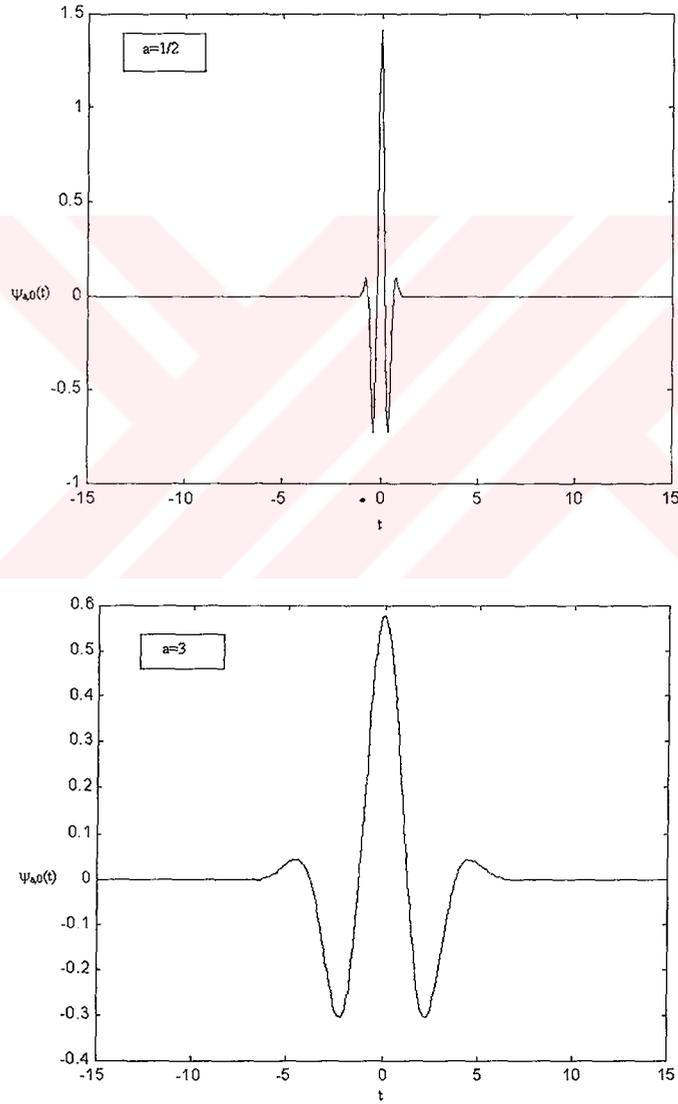
eşitliği vardır ve normalize faktörü $1/\sqrt{|a|}$, enerjinin bütün a ve b değerleri için aynı aralıkta kalmasını sağlar;

$$\int_{-\infty}^{\infty} |\psi_{a,b}(t)|^2 dt = \int_{-\infty}^{\infty} |\psi(t)|^2 dt \quad (3.10)$$

Herhangi bir a değeri için $\psi_{a,b}(t)$ fonksiyonu, zaman eksenini üzerinde b oranında $\psi_{a,0}(t)$ 'nin ötelenmesi ile bulunur. Burada b değişkeni zamanda ötelemeyi veya dönüştürmeyi gösterir.

$$\psi_{a,0}(t) = \frac{1}{\sqrt{|a|}} \psi\left(\frac{t}{a}\right) \quad (3.11)$$

Bu eşitlikteki $\psi_{a,0}(t)$, $\psi(t)$ 'nin zaman-ölçekli ve genlik-ölçekli uyarlamalarına karşılık düşer. Şekil 3.4 'de Morlet dalgacığının a parametresine bağlı değişimi görülmektedir. $0 < a < 1$ aralığında $\psi(t)$, daralmakta ve $a > 1$ değerlerinde genişlemektedir. a 'nın negatif değerleri için öteleme ile birlikte zamanda dönüşüm sağlanır. Böylelikle tekil fonksiyon olan $\psi(t)$ fonksiyonunun ötelenmesi ve dönüşümü ile SDD sağlanır (Rao ve Bopardikar, 1998).



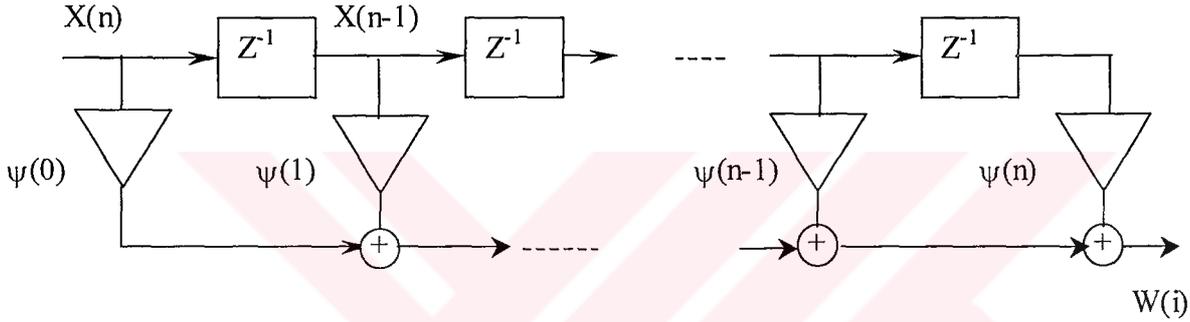
Şekil 3.4 Morlet Dalgacığının farklı genişleme değerlerine göre değişimi ($a=1/2$ ve $a=3$)

3.2.2 Ayrık Dalgacık Dönüşümü

Sürekli dalgacık dönüşümünün eşitlik (3.5) genel ifadesinin ayrık zamandaki yazılımı şu şekilde ifade edilir,

$$W[iT_s, a] = T_s \frac{1}{\sqrt{a}} \sum_{n=1}^N \psi^* \left[\frac{[n-i]T_s}{a} \right] x[nT_s] \quad (3.12)$$

N , örnekleme sayısı; T_s , örnekleme aralığı ($T_s = 1/f_s$, f_s örnekleme frekansı) ve i , zaman konumunu belirten indekstir. Eşitlik (3.12)'un FIR filtre yapısı olarak çizimi Şekil 3.5'de görülmektedir.



Şekil 3.5 Ayrık dalgacık dönüşümünün FIR filtre karşılığı (Engin, 1998).

Bu yapının uygulanması Şekil 3.6' da görülmektedir. Her bir bandede alçak-geçiren/yüksek-geçiren filtre çiftleri band geçiren filtre takımı olarak çalışır. Bu filtre ağaç yapısı, işaretleri logaritmik olarak frekanslarına ayırır (Şekil 3.7). $W(1)$ kısmından sonra işaret ikiye bölünmüştür; yüksek frekans bileşeni dönüşüm sonucu olarak tanımlanır, alçak frekans bileşeni diğer ayrışımalar olarak ortaya çıkar. Bu düşük frekans bileşeni, frekans bandı ikiye bölündüğünden dolayı Nyquist kriterine göre örnek sayısı yarıya düşürülebilir. Böylelikle filtre sonuçlarının bu kritere göre azaltılması bilgi kaybına neden olmaz.

Filtre bankaları kullanılarak elde edilen dalgacık katsayıları SDD'nin alt örnekleridir. Bu nedenle ayrık dalgacık dönüşümü (ADD) için temel fonksiyonlar olarak kullanılan dalgacıklar ortogondur. Ortogonallik, gereksiz bilginin içermediğini göstermektedir. Bir diğer önemi de, sınırlı işaretler temel fonksiyonların ağırlıklı toplamları olarak ifade edilebilir veya ağırlıklı fonksiyonlar kullanılarak işaret tekrardan elde edilebilir. Özellikle Daubechie'nin ortogonal dalgacıkları, ADD'yi oldukça pratikleştirmiştir.

Ortogonal dalgacıklar, genişleme eşitliklerinden elde edilir. $\phi(x)$ fonksiyonu, $\phi(2x)$ 'in genişleme ifadelerinden oluşan seri olarak yazılabilir. Herbir $\phi(2x)$ terimleri $(2x-k)$

(k tamsayıdır) argümanlarını kullanarak x -ekseninde farklı bir noktayı gösterir. Dalgacık fonksiyonlarının genişleme eşitlikleri şu şekilde ifade edilirler,

$$\phi(x) = c_0\phi(2x) + c_1\phi(2x-1) + c_2\phi(2x-2) + c_3\phi(2x-3) \quad (3.13)$$

$$\phi(x) = \sum_{k=0}^{N-1} c_k\phi(2x - k) \quad (3.14)$$

c , sayısal sabit ve N , katsayıların toplam sayısı. Çok az örnek dışında (3.13) eşitliğinde direkt olarak $\phi(x)$ 'in bulunması mümkün değildir. En basit çözüm iteratif yöntemdir. Özel olarak aşağıdaki katsayılar kullanılabilir:

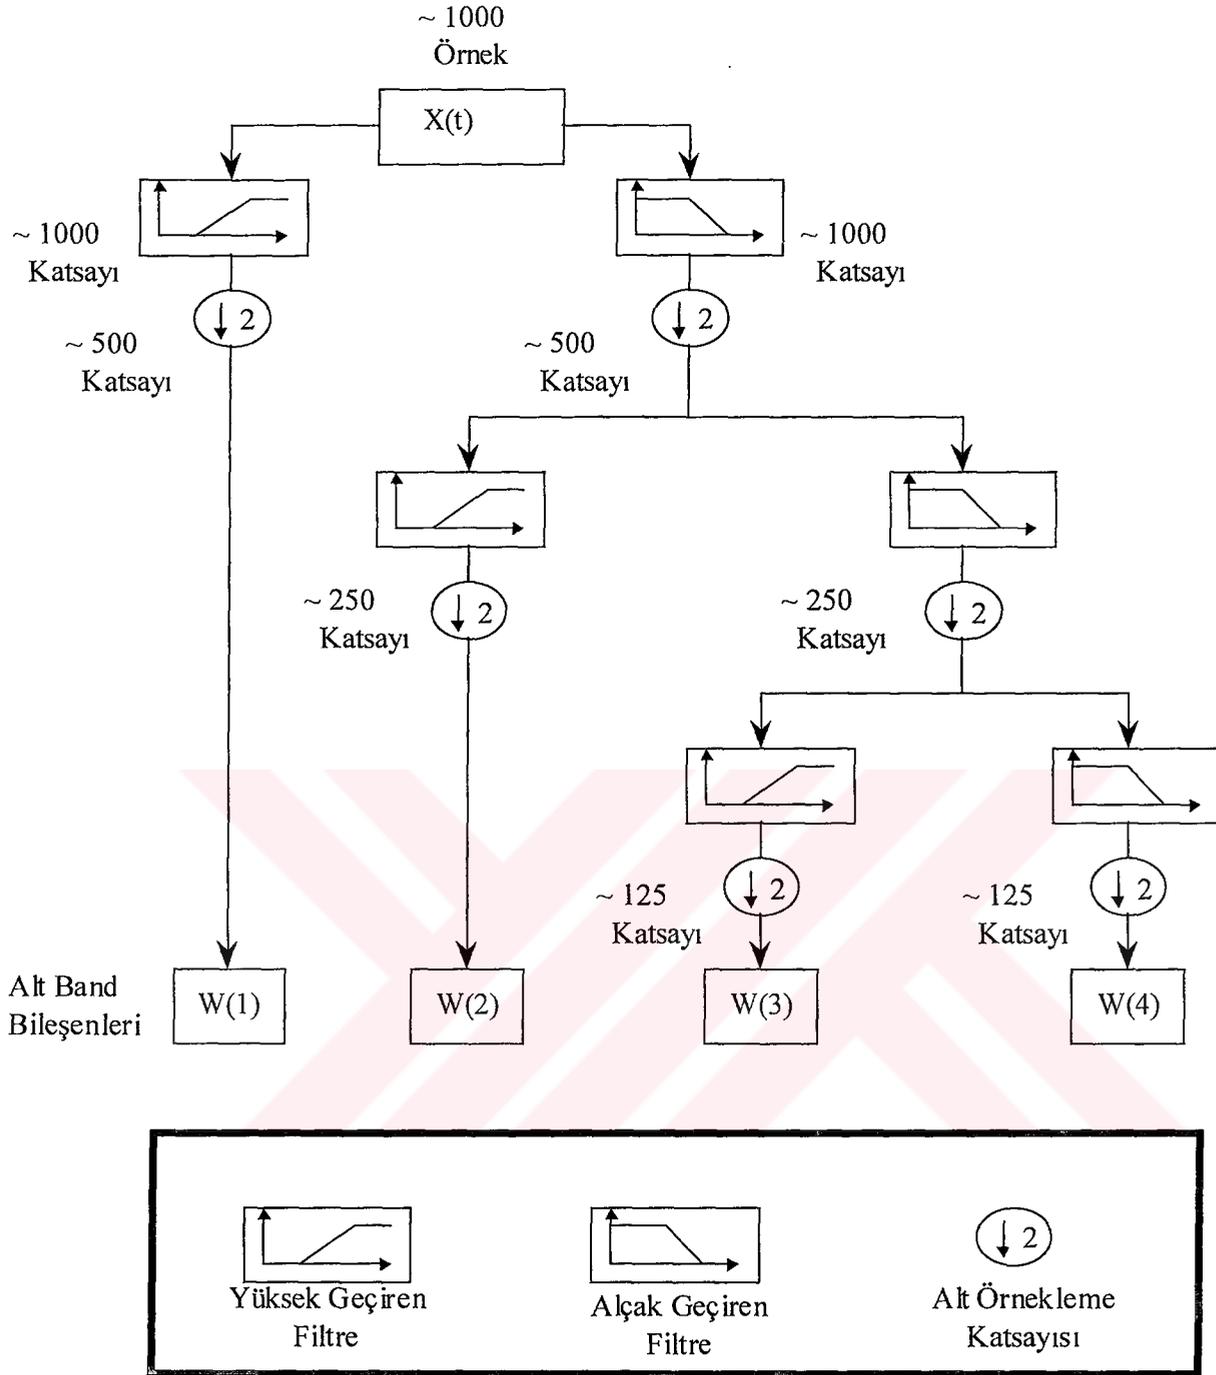
$$c_0 = (1 + \sqrt{3})/4, \quad c_1 = (3 + \sqrt{3})/4, \quad c_2 = (3 - \sqrt{3})/4, \quad c_3 = -(-1 + \sqrt{3})/4 \quad (3.15)$$

Bu katsayılar ortogonal D4 dalgacığı sonuçlarıdır. Daubechie ortogonal dalgacıkların özelliklerini ilk ortaya koyan olmasından dolayı Daubechie'nin D'si literatürde kullanılmaktadır. Katsayılar, dalgacık fonksiyonlarının ortogonal özellikleri kullanılarak hesaplanmış ve 1988 yılında Daubechie tarafından yayınlanmıştır.

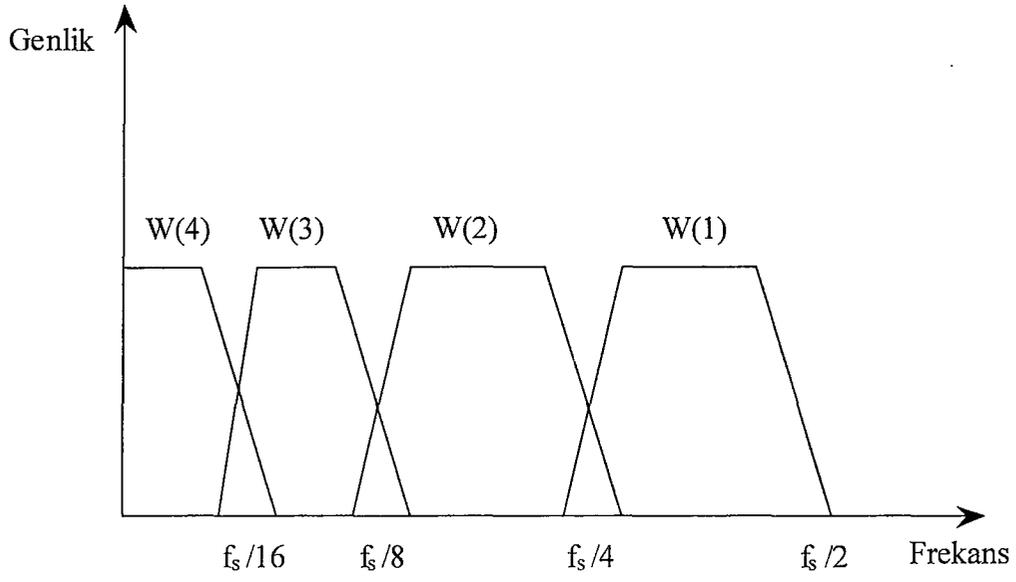
Ölçekleme fonksiyonu olarak adlandırılan $\phi(x)$ kullanılarak dört katsayılı dalgacık fonksiyonu ψ veya W şu şekilde yazılır:

$$W(x) = -c_3\phi(2x) + c_1\phi(2x-1) - c_1\phi(2x-2) + c_0\phi(2x-3) \quad (3.16)$$

Aynı katsayılar ters sıra ve işaret farklılıkları ile $\phi(x)$ 'i tanımlamak için kullanıldığı görülmektedir (Engin, 1998).



Şekil 3.6 Filtre bankaları kullanılarak ADD'nün altbandlara ayrışım yöntemi olarak uygulanması (Engin, 1998).



Şekil 3.7 ADD'nin frekans domeni ayrımı (Engin, 1998).

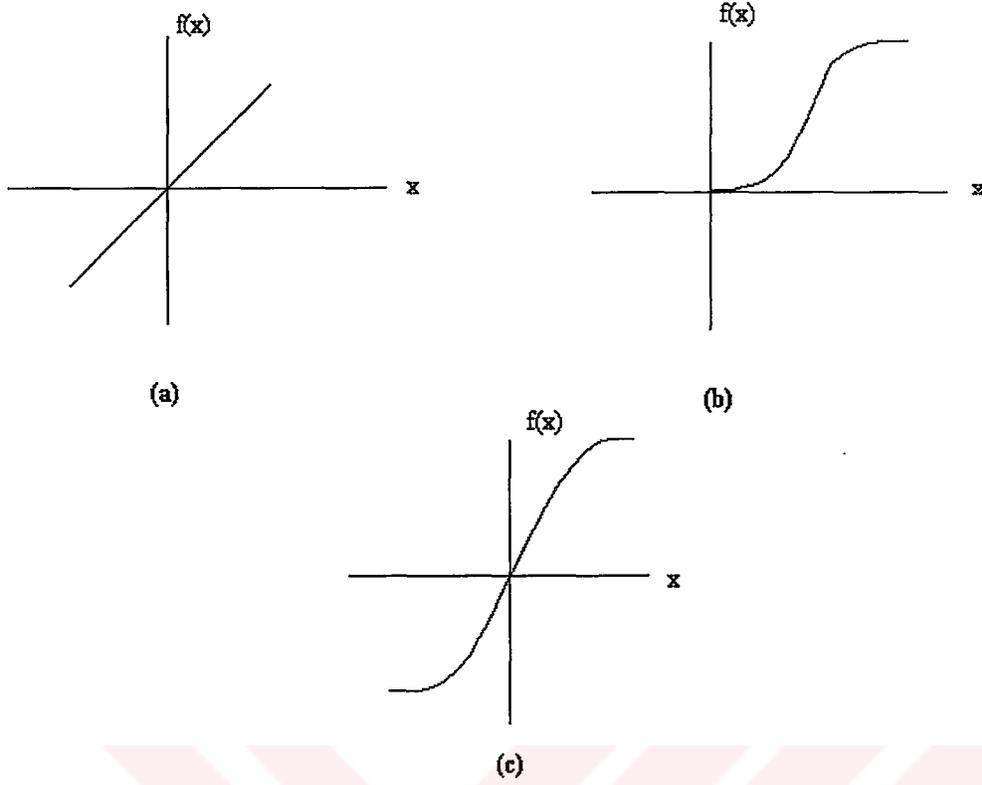
4. DALGACIK YAPAY SINIR AĞI

Dalgacık teorisinin gelişim sürecinde, işaret ve görüntü ayrıştırmadaki klasik yöntemlere göre üstün özelliklerinin ortaya çıkması, araştırmacıları bu alanda yoğun çalışmaya sevk etmiştir. Yapay sinir ağlarının da işaret ve görüntü işleme uygulamalarında başarılı sonuçlar vermesi bu iki yöntemin birlikte kullanılabilmesi konusunda çalışmalar yapılmasını sağlamıştır. Bu çalışmalarda dalgacık dönüşümü özellik çıkarımı amaçlı ön işleme biriminde kullanılır. Bu birimde elde edilen özellik vektörleri yapay sinir ağlarının giriş kümesini oluşturur. Bu yapının kullanıldığı uygulamalarda dalgacık dönüşümü sonucunda elde edilen öznelik vektörlerinin çok iyi sonuçlar verdiği görülmüştür.

Dalgacık dönüşümünün esas yapısını oluşturan dalgacık fonksiyonları ikinci bölümde incelenmiştir. Bu fonksiyonların sahip oldukları özellikler, işaretlerin kayıpsız bir şekilde analizine olanak sağlamaktadır. Bu analiz özelliğinin yapay sinir ağlarında yakınsamaya katkısının incelenmesi amacı ile dalgacık fonksiyonlarının aktivasyon fonksiyonu olarak kullanımı gerçekleştirilmiştir. Öncelikle en uygun dalgacık fonksiyonu araştırması yapılmıştır. Bu inceleme sonucunda seçilen dalgacık fonksiyonu ileri yönlü çok katmanlı ağ yapısında kullanılmıştır. Bu ağ *Dalgacık Yapay Sinir Ağı (DYSA)* olarak adlandırılmıştır. DYSA'nın yakınsama performansının incelenmesi amacı ile fonksiyon yaklaşımı, biyomedikal işaretlerin sınıflanması ve aydınlatma düzeyinin hesaplanması uygulamaları yapılmıştır. Bu uygulama sonuçları ile klasik çok katmanlı ağların sonuçları karşılaştırmalı olarak incelenmiştir.

4.1 Dalgacık Yapay Sinir Ağının Mimarisi

Dalgacık yapay sinir ağı, bir giriş katmanı, bir gizli katman ve bir de çıkış katmanından oluşmaktadır. Bu ağın gizli katmanında dalgacık fonksiyonu ve çıkış katmanında doğrusal fonksiyon kullanılmıştır. DYSA'nın eğitiminde geriye yayılım (Backpropagation) algoritması kullanılmıştır. Bu algoritmanın işleyişinde aktivasyon fonksiyonlarının türevi alınabilir olması zorunludur. Yaygın kullanıma sahip çok katmanlı ağlarda (ÇKA) aktivasyon fonksiyonu olarak log-sigmoid, hiperbolik tanjant sigmoid ve lineer fonksiyonlar kullanılmaktadır (Şekil 4.1).



Şekil 4.1 ÇKA’da kullanılan aktivasyon fonksiyonları, a) Lineer, b) Logaritmik sigmoid, c) Hiperbolik tanjant sigmoid

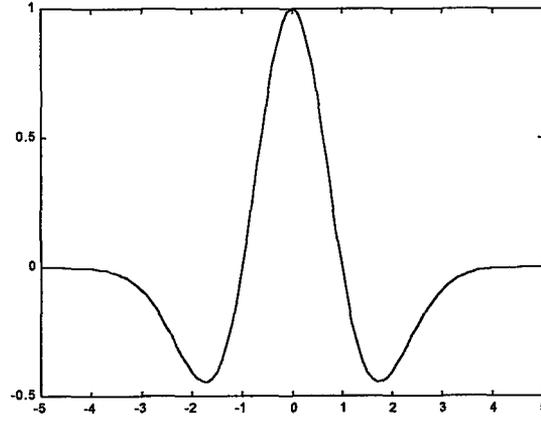
Dalgacık fonksiyonunun seçiminde türevi alınabilir olması ve geriye yayılım algoritmasında kullanılabilir olması şartları aranmıştır. Bu araştırmalar sonucunda, dalgacık analizinde geniş bir kullanım alanına sahip olan Haar dalgacığı sürekli olmadığından dolayı tercih edilmemiştir. Morlet dalgacığının ve Meksika Şapkası fonksiyonları üzerinde çalışmalar sonucunda Meksika Şapkasının yüksek performans sağladığı görülmüştür. Bu amaçla DYSA’nın gizli katmanında Şekil 4.2 ‘de görülen Meksika şapkası transfer fonksiyonu olarak kullanılmıştır.

Bu fonksiyonun ifadesi şu şekildedir;

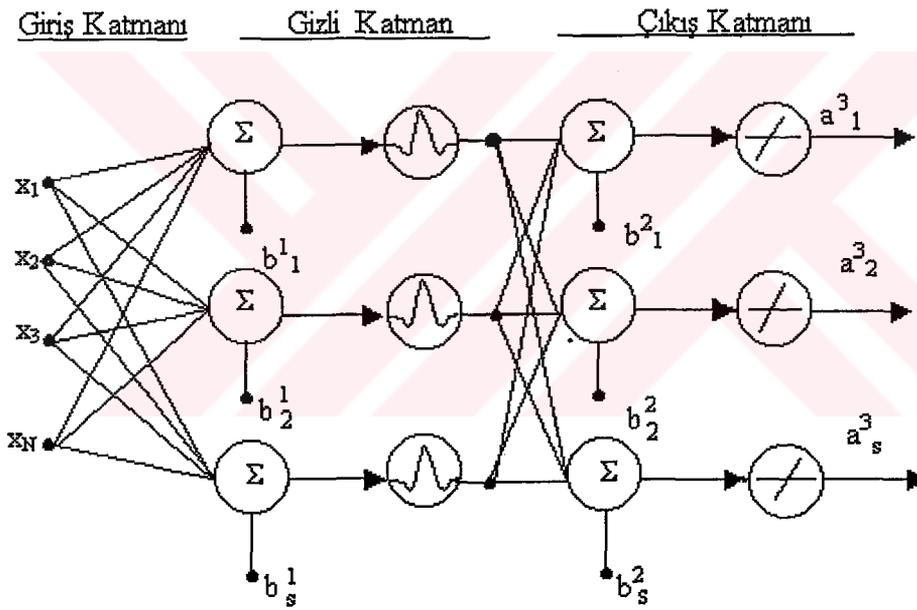
$$\psi = (1 - x^2)e^{-x^2} \quad (4.1)$$

DYSA’nın çıkış katmanında kullanılan doğrusal fonksiyonun ifadesi 4.2 eşitliğinde verilmiştir. (Şekil 4.1a)

$$y = x \quad (4.2)$$



Şekil 4.2 Meksika şapkası fonksiyonu



Şekil 4.3 DYSA'nın mimarisi

Şekil 4.3'de görülen DYSA'nın ileri yönlü yayılım ifadesi şu şekildedir:

$$y = w^2 (\psi (w^1 \cdot x + b^1)) + b^2 \quad (4.3)$$

Burada;

w^1 : Birinci katman için bağlantı ağırlık matrisi,

x : Giriş kümesi ,

w^2 : Dalgacık nöronları ile çıkış katmanı arasındaki bağlantı ağırlıkları (dalgacık katsayıları)

b^1 ve b^2 : Her bir katmandaki eşik değerleri,

ψ : Dalgacık fonksiyonudur.

4.2 Dalgacık Yapay Sinir Ağının Eğitimi

Yapay sinir ağlarının eğitimindeki amaç, hedeflenen çıkışlar ile giriş kümesi arasındaki ilişkinin aktivasyon fonksiyonları, ağırlık katsayıları ve eşik değerlerinden oluşan bir bağıntı ile ifade edilebilmesidir. Bu ilişkinin kurulmasındaki sınırlayıcı ölçü ise ağın çıkışları ile hedeflenen değerler arasındaki hata oranıdır. Ağ eğitimi esnasında bu hatayı minimize etmeye yönelik adımsal olarak ağırlık katsayılarını ayarlar.

Dalgacık yapay sinir ağında dalgacık fonksiyonlarının kullanılma amacı, bu fonksiyonların analizde kullanılan öteleme ve ölçekleme özelliklerinin yakınsama hızını artırıcı etki yapacağı varsayımdır. Yakınsama hızının artması hatanın kısa sürede minimize edilmesi ve ağ eğitiminin daha kısa sürede tamamlanması anlamına gelmektedir. Bu özelliğin daha iyi anlaşılması için dalgacık dönüşümü ile ağın yapısı arasındaki ilişkiye bakmakta fayda vardır.

Ayrık dalgacık dönüşümünde (ADD) örnekleme kafesinin istenilen ölçeklerde ayarlanması amacı ile 'a' ölçekleme ve 'b' öteleme parametrelerinin seçimi şu şekilde yapılır:

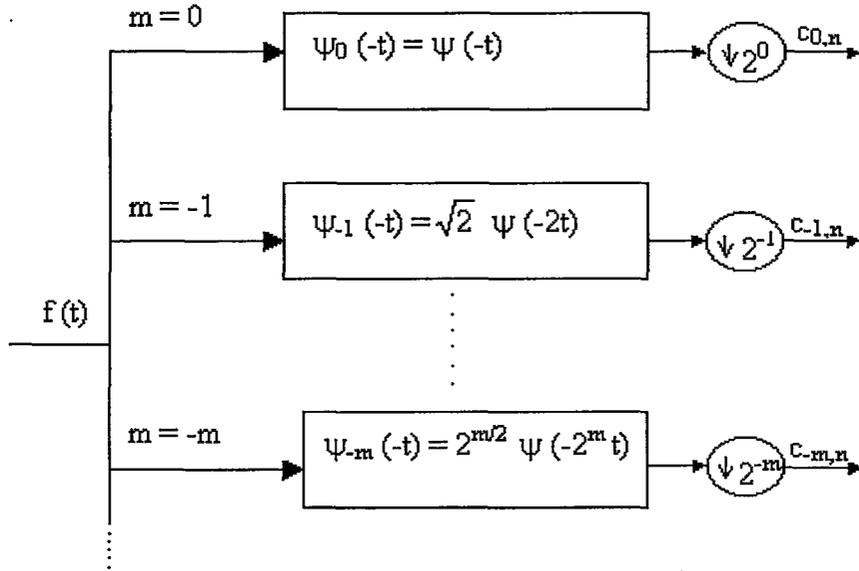
$$a = a_0^m \quad b = n b_0 a_0^m \quad m, n \in Z \quad (4.4)$$

Buradan analiz fonksiyonu $\psi_{j,k}$ eşitliği,

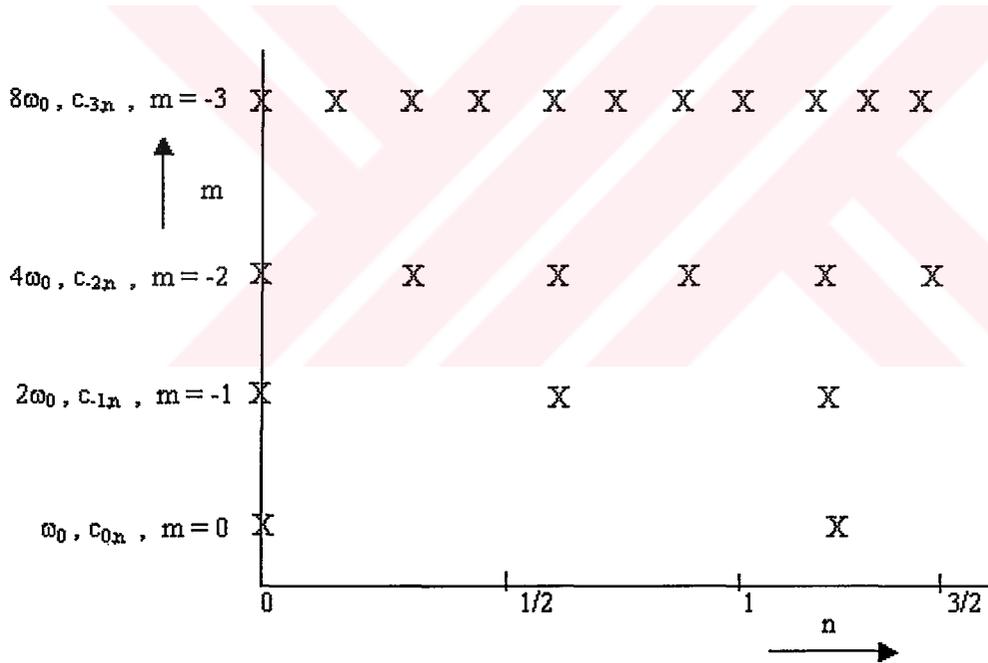
$$\psi_{j,k} = a_0^{-m/2} \psi(a_0^{-m} t - n b_0) \quad (4.5)$$

olarak yazılabilir.

ADD'nin filtre bankaları kullanılarak gerçekleştirilmesinde bu eşitlik kullanılır. Şekil 4.4 ve Şekil 4.5 'de görülen ayrıştırma oranları 'm' parametresine bağlı olarak değişmektedir.



Şekil 4.4 ADD filtre bankası



Şekil 4.5 ADD nin ikili alt örnekleme gösterimi

DYSA'nın çıkış-giriş ilişkisini gösteren 4.3 eşitliğindeki b^1 ve b^2 eşik değerleri ağırlık değeri 1 olan girişler olarak ifade edilebilir ve w^1, w^2 ağırlık matrislerinin içerisinde gösterilebilirler. Bu düzenleme sonrasında DYSA'nın eşitliğini tekrardan yazarsak,

$$y = w^2 \cdot \Psi(w^1 \cdot x) \quad (4.6)$$

ifadesi elde edilmiş olur.

Bu ifade ile (4.5) eşitliği karşılaştırıldığında aşağıdaki eşitlikler elde edilir,

$$w^2 = a_0^{-m/2} \quad (4.7)$$

$$w^1 = a_0^{-m} \quad (4.8)$$

$$n b_0 = 0 \quad (4.9)$$

Bu ifadelerdeki 'm' parametresinin değişimi ADD'de olduğu gibi sabit aralıklı değildir. Eğitim algoritmasının işleyişine göre, hatayı minimize etmeye yönelik bir değişim göstermektedir. Böylelikle ağırlık yakınsaması çok daha hızlı olmaktadır. Bu teorik sonuçların uygulama ile somut olarak görülebilmesi için DYSA'nın eğitim ve test fazları Matlab programlama dili kullanılarak gerçekleştirilmiştir. Ağırlık eğitimi için Bölüm 2.4'de anlatılan geriye yayılım algoritması kullanılmıştır. Bu algoritmanın işlem adımları şu şekildedir:

1. Adım :

Eğitim kümesinden sıra ile tüm vektörleri ağa giriş olarak ver.

2. Adım:

Giriş verilerini birinci katmandaki ağırlık değerleri ile çarparak transfer fonksiyonuna gir ve çıkışlarını ikinci katmana aktar.

3. Adım:

İkinci katmandaki düğüm değerlerini ω^2 ağırlıkları ile çarp ve çıkış değerlerini son katmana ulaştır.

4. Adım:

Çıkış değerini hedef çıkış değeri ile karşılaştır. Bulunan hata oranı istenilen hata oranından

- a) Büyük ise iterasyon sayısını azalt ve hatayı minimum yapacak şekilde giriş katmanına doğru ağırlıkları ayarla (geriye yayılım) ve birinci adıma dön.
- b) Küçük veya eşit ise eğitimi sonuçlandır.

4.3 Dalgacık Yapay Sinir Ağının Performans Analizi

DYSA'nın eğitim ve test fazlarındaki yakınsama hızını karşılaştırmalı olarak görmek amacı ile suni ve gerçek veriler kullanılarak uygulamalar yapılmıştır. Karşılaştırma için öğrenme oranı, gizli katman sayısı, her bir katmandaki düğüm sayısı, istenilen hata oranı ve çıkış transfer fonksiyonlarının aynı olduğu çok katmanlı ağ yapıları seçilmiştir.

Performans analizinde,

- Elektromiyografik işaretlerin sınıflandırılması
- Fonksiyon yaklaşımı
- Aydınlik düzeyi hesaplanması

uygulamaları üzerinde çalışmalar yapılmıştır.

4.3.1 Elektromiyografik İşaretlerin Sınıflandırılması Problemi

4.3.1.1 Elektromiyografik işaret nedir?

Elektromiyogram (EMG), kasın kasılması sonucu ortaya çıkan ve kaynağı elektro kimyasal olaylar olan biyopotansiyel işaretlerdir. EMG işaretleri, vücuttan özel elektrotlar yardımıyla alınırlar ve elektrot çeşidine göre farklı adlarla anılırlar. İşaretlerin değerlendirilmesi zaman domeninde ve/veya frekans domeninde yapılabilir. EMG, klinik uygulamalarda hastalık teşhislerinde ve kol kesilmesi gibi durumlarda kesik yere takılan protezin hareket ettirilmesini sağlayacak kaynak işaret olarak kullanılır. Protez kontrolü, bir çift yüzey elektrodundan sağlanan miyoelektrik işaretler kullanılarak yapılabilir. Bu durum özellikle dirsek üstünden kolunu kaybetmiş vakalarda uygulanabilir. Kontrol işlemi, her bir hareket için aynı olan ve tekrarlanabilen kas kasılma karakterleri kümesinin oluşturduğu miyoelektrik işaretlerden kolaylıkla çıkarılan karakteristik parametrelerle yapılır. Bu parametreler kullanılarak farklı kas kasılmalarına ait karakterleri sınıflara ayırmak mümkündür. Kas kasılması sınıflarının her biri, protez cihazının özel bir fonksiyonunu tetiklemek için kullanılır. Sınıflar arasında iyi bir ayırım yapabilmek için, protez alet yerine takıldığında normal kol fonksiyonu ile hiçbir benzerlik göstermeyebilen olağan dışı kas kasılmalarının bir setinin de üretilmesi gerekebilir. Farklı kas kasılma karakterlerini ayırma kabiliyeti, kaslardan gelen miyoelektrik bilgisine bağlıdır. Örnek olarak; üç kasın yakınına yerleştirilmiş bir çift deri yüzey elektrodundan elde edilen işaret, üç kastan her birinin aktivitesine ait bilgiler içerecektir. Yüzey elektrodunun

yakınlarında birkaç kas varsa, sonuçta oluşan miyoelektrik işaret her kastaki aktiviteye ait bilgiler içerir. Kas setinin içindeki kasılmalardan oluşan karakter, alınan işaretten çıkarılan özelliklere dayalı olarak tanımlanabilir. Graupe (1975) tarafından gerçekleştirilen deneylere dayalı olarak, bu tip kas hareketlerinin, miyoelektrik işaret özelliklerinin olduğu kümelerden tanımlanabileceği söylenebilir. Normal kol fonksiyonlarının kümesi ile bileşik kas kasılma karakterleri arasında önemli bir fark varsa, normal kol fonksiyonlarının direkt tanımlanmasına bağlantılı olan miyoelektrik işaretlerin sınıflandırılması yapılabilir.(Özyılmaz, 2000)

4.3.1.2 EMG işaretlerinin Modellenmesi

EMG işaretlerinin genlik değerleri tepeden tepeye 0–6 mV veya 0-1.5 mV değerler arasında değişirler. İşaretin kullanışlı enerjisi baskın bölge 50–150 Hz olmak üzere 0–500 Hz frekansları ile sınırlıdır. Kullanışlı işaretlerden anlaşılan, elektriksel gürültü seviyesinin üstünde enerjiye sahip işaretler olmalıdır. Ölçülen miyoelektrik işaretlerin bir yapay sinir ağına uygulanabilmesi için, hücrelerin polarizasyon ve depolarizasyon sonucu ortaya çıkan; yani, fiziksel bir anlamı olan kavramların matematiksel ifadelerle dönüştürülmesi gerekir. Bu işleme, modelleme denir. Sistem modellemesi için AR (Auto-Regressive) katsayıları kullanılmıştır. Elektromiyografik işaretlerin yeterince küçük zaman aralıklarında örneklenmesi halinde durağan sayılabilmesi, AR modelinin kullanılmasına olanak sağlamaktadır.

4.3.1.3 AR Katsayıları

Sistemlerin çoğu, geçmişteki çıkışlarının, o andaki ve geçmişteki girişlerinin lineer kombinasyonları ile modellenebilir. Matematiksel olarak bu, aşağıdaki gibi gösterilebilir.

$$y_k = \sum_{i=1}^M a_i y_{k-i} + \sum_{j=0}^N b_j x_{k-j} \quad (4.10)$$

Burada x_k ve y_k sistemin ayrık zamandaki giriş ve çıkış serileridir. Girişe ait herhangi bir bilgiye erişilemiyorsa (EMG işaretlerinde olduğu gibi), giriş beyaz gürültü olarak alınabilmektedir. Yukarıdaki eşitlikten görüldüğü gibi model parametreleri olan ‘ a_i ’ ($i = 1, 2, \dots, M$) ve ‘ b_j ’ ($j=1, 2, \dots, N$) bilindiği takdirde, geçmişteki giriş ve çıkış değerlerinden k anındaki y_k değeri hesaplanabilir. Bu nedenle, bu modelleme doğrusal kestirim (linear prediction) olarak da adlandırılır. (4.10) eşitliğinin Z dönüşümü alınarak sistemin transfer fonksiyonu

$$H(z) = \frac{Y(z)}{X(z)} = \frac{\sum_{j=0}^N b_j Z^{-j}}{1 + \sum_{i=1}^M a_i Z^{-i}} \quad (4.11)$$

olarak bulunur. Sıfırları ve kutupları içeren bu genel model ARMA (Auto-Regressive Moving Average) olarak adlandırılır. b_j katsayılarının sıfır olduğu durumda sistem, yalnızca çıkışlar kullanılarak modellenir. Tüm kutup veya AR model olarak anılan bu tanımın fark denklemleri ile gösterimi

$$y_k = -\sum_{i=1}^M a_i y_{k-i} + b_0 x_k \quad (4.12)$$

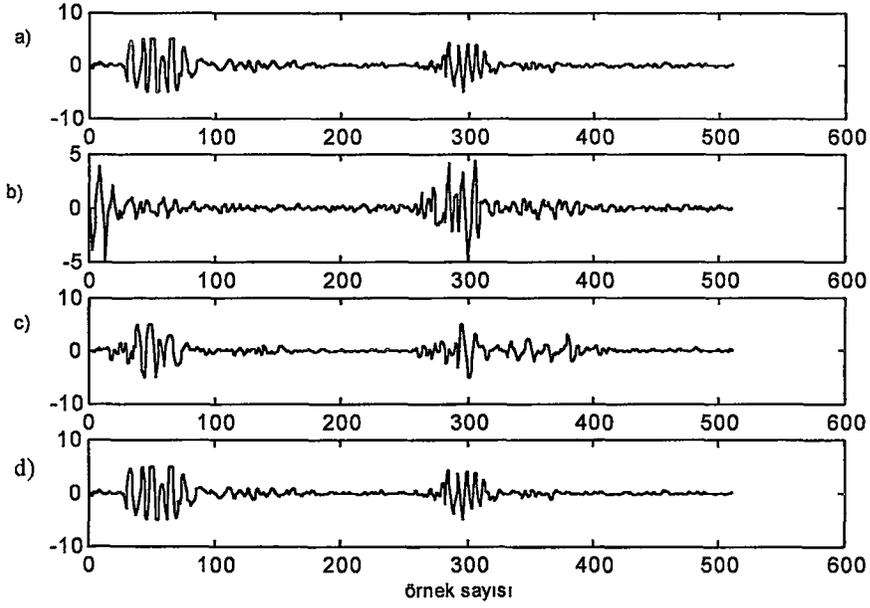
şeklinindedir. EMG işaretleri, yeterince küçük zaman aralıklarında örneklenmesi halinde durağan sayılabildiği için AR modeli kullanılabilir. Bu noktadan sonra yapılacak olan (4.12) denklemindeki a_i ve b_0 'ı yani AR katsayılarını bulmaktadır.

4.3.1.4 EMG İşaretlerinin Yapay Sinir Ağlarına Uygulanması

EMG işaretlerinin ağa giriş verisi olarak girilebilmesi için öncelikle yukarıda anlatıldığı gibi matematiksel ifadelerle dönüştürülmesi gereklidir. Kaslardan alınan EMG işaretlerinin AR katsayıları modellenmesi ile oluşan giriş kümesi seti 4 sınıfa ait 24 örnek işareten oluşmaktadır. Bu EMG işaretleri;

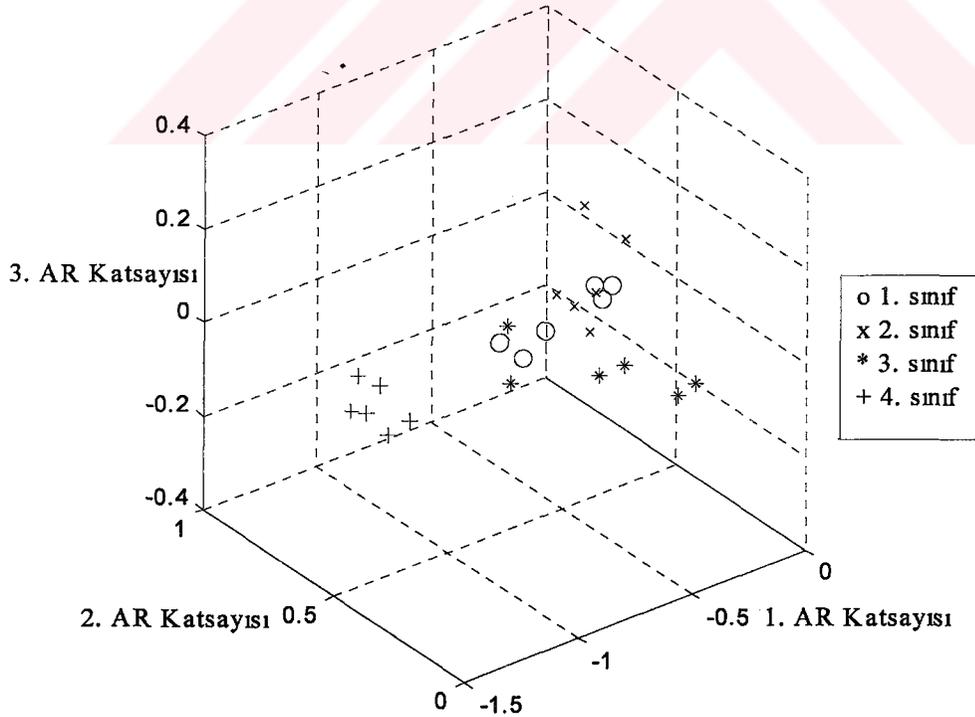
- kolu içe hareket ettirme,
- kolu dışa hareket ettirme,
- dirsek açma
- dirsek kapama

hareketlerine aittirler (Şekil 4.6).

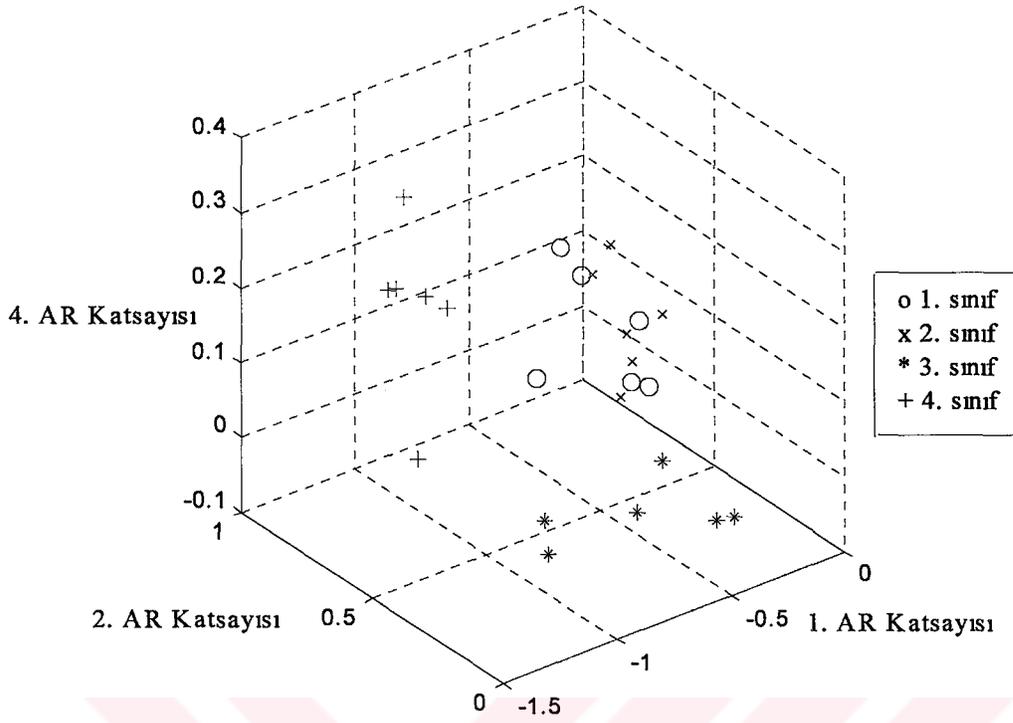


Şekil 4.6 a) 1.Sınıfa ait kolu içe hareket ettirme işareti, b) 2. Sınıfa ait kolu dışa hareket ettirme işareti, c) 3. Sınıfa ait dirsek açma işareti, d) 4. Sınıfa ait dirsek kapama işareti

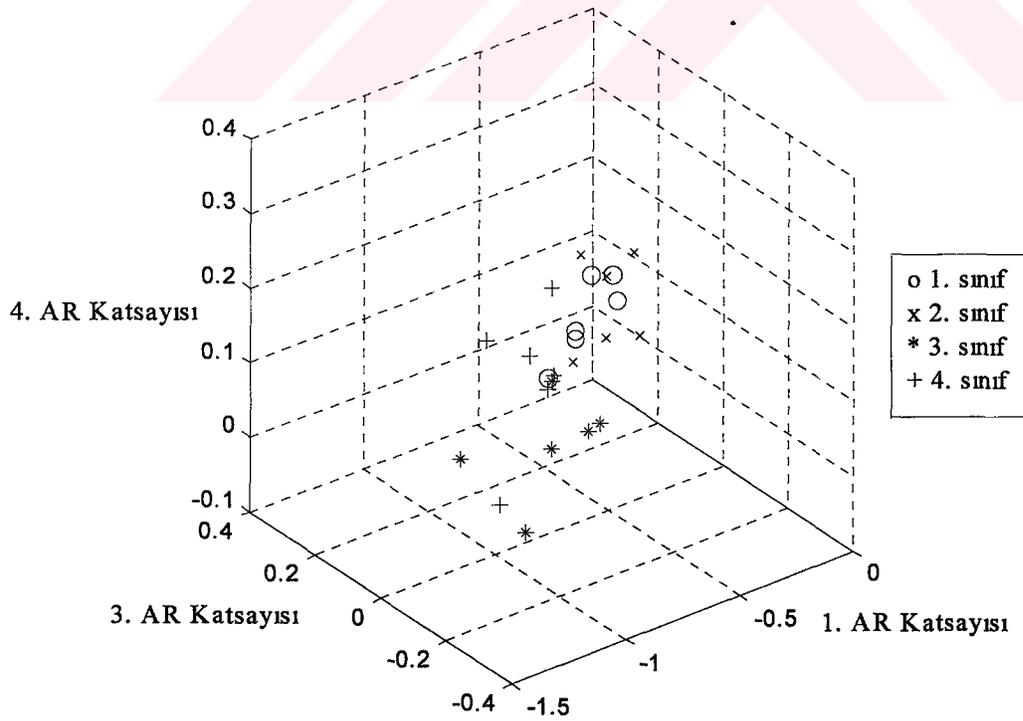
Bu işaretlerin 6. dereceden AR katsayılarının üç boyutlu uzayda dağılımları Şekil 4.7’de görülmektedir. Veri kümesine ait detaylar Ek 1’de verilmiştir.



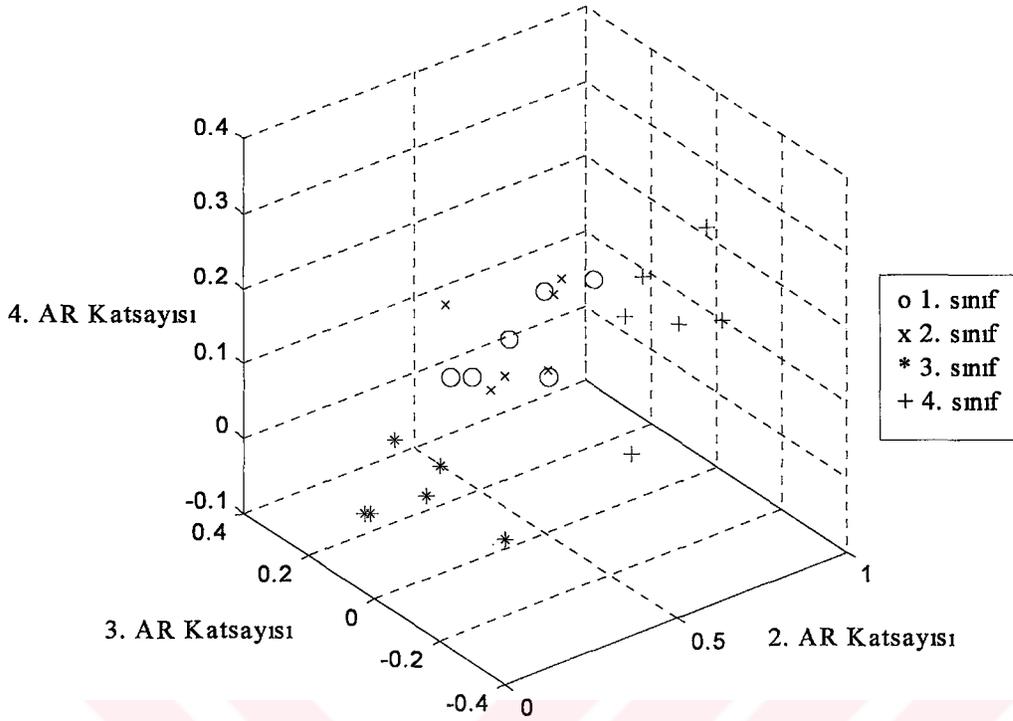
Şekil 4.7 EMG işaretlerinin 1., 2. ve 3. AR katsayılarına göre sınıfsal dağılımı



Şekil 4.8 EMG işaretlerinin 1., 2. ve 4. AR katsayılarına göre sınıfsal dağılımı



Şekil 4.9 EMG işaretlerinin 1., 3. ve 4. AR katsayılarına göre sınıfsal dağılımı



Şekil 4.10 EMG işaretlerinin 2. ,3. ve 4. AR katsayılarına göre sınıfsal dağılımı

Eğitim amaçlı olarak her bir sınıftan 3 örnek kullanılmıştır. Bu örnekler dalgacık yapay sinir ağına ve farklı aktivasyon fonksiyonları kullanan iki çok katmanlı ağa uygulanmıştır. Bu ağlardan ÇKA¹'in aktivasyon fonksiyonu logaritmik-sigmoid ve ÇKA²'nin aktivasyon fonksiyonu hiperbolik tanjant sigmoiddır. Bu üç ağın aktivasyon fonksiyonlarının, eğitim hızlarına etkisini gözlemleyebilmek için diğer özellikleri eşit olarak seçilmiştir. Her bir ağda bir gizli katman , eşit sayıda düğüm ve çıkış katmanı aktivasyon fonksiyonu olarak “y = x” doğrusal fonksiyonu vardır. Eğitim ve test programı Pentium II. 300 işlemcili ve 32 MB hafızalı bir PC’de gerçekleştirilmiştir. Kullanılan bilgisayarda 100 iterasyon ortalama olarak 1.5-2 ms’ye sürmektedir.

4.3.1.5 Eğitime ve Test Sonuçları

Bu uygulamada, sınıflama başarımı ve hata oranı sabit tutularak eğitim hızının karşılaştırılması amaçlanmıştır. ÇKA¹, ÇKA² ve DYSA’nın gizli katman düğüm sayılarının farklı değerleri için eğitimi gerçekleştirilmiştir. Herbir eğitim için iterasyon sayısında bir kısıtlama olmadığından, istenilen hata oranına ulaşıldığında öğrenme sonlandırılmıştır. Hata oranı sabit tutularak gizli katman düğüm sayılarına göre eğitim iterasyon sayıları ve eğitim

süreleri Çizelge 4.1 ve Çizelge 4.2 'de verilmiştir.

Ağların eğitiminde hata oranı sabit tutulduğundan test fazında sınıflama başarımı her bir ağ için eşit olarak %83,3 bulunmuştur. Bu uygulamada eğitim hızları incelendiğinden sınıflama başarımını artıracak daha uygun öznitelik vektörlerinin seçilmesine ait yöntemler üzerinde durulmamıştır.

Çizelge 4.1 ÇKA¹, ÇKA² ve DYSA'nın gizli katman düğüm sayılarının farklı değerleri için eğitim iterasyon sayıları

<i>Gizli Katman Düğüm Sayısı</i>	<i>5</i>	<i>6</i>	<i>7</i>	<i>8</i>	<i>9</i>	<i>10</i>
ÇKA¹	5787	16156	9835	11596	9762	9749
ÇKA²	1300	1222	1333	1947	1942	2553
DYSA	551	938	606	643	516	592

Çizelge 4.2 ÇKA¹, ÇKA² ve DYSA'nın gizli katman düğüm sayılarının farklı değerleri için saniye cinsinden eğitim süreleri

<i>Gizli Katman Düğüm Sayısı</i>	<i>5</i>	<i>6</i>	<i>7</i>	<i>8</i>	<i>9</i>	<i>10</i>
ÇKA¹	141,98	514,6	420,72	490,43	436,66	689,54
ÇKA²	30,05	36,03	46,08	77,78	85,74	135,72
DYSA	19,06	35,26	25,76	33,94	30,05	39,22

4.3.2 Fonksiyon Yaklaşımı Problemi

Kendi aralarındaki ilişki ifadesi bilinmeyen verilerden yola çıkarak en uygun fonksiyonun bulunması işlemi fonksiyon yaklaşımı olarak tanımlanır. Ölçülen veya uygulamalar sonucunda elde edilen verilerin ara değerlerin bulunması özellikle mühendislik alanlarında sıkça rastlanılan problemlerdir. Bu problemin çözümünde kullanılan klasik yöntemlere polinomsal yaklaşım, üssel ve logaritmik yaklaşımlar örnek olarak verebilir. Bu yöntemlere alternatif olarak yapay sinir ağlarında hata oranının belirlenmesinin kullanıcıya ait olması çok

kısa zaman aralığında minimum hata ile fonksiyonun bulunabilmesine imkan sağlamaktadır.

Bu bölümdeki uygulamada, hata oranında görülebilmesi amacı ile bilinen bir

$$y = \frac{\sin(x) * \cos(x)}{2}$$

fonksiyonu ağın hedef fonksiyonu olarak seçilmiştir. Eğitim kümesi olarak x'in [-2,2] aralığındaki 0.4 aralıklı değerleri alınmıştır. Hedef değerler ise bu x değerlerine karşılık gelen y değerleridir.

ÇKA¹ ağının giriş-çıkış ilişkisini veren y₁ fonksiyonun ifadesi şu şekildedir:

$$y_1 = w^2 (\text{logsig}(w^1 \cdot x + b^1)) + b^2 \quad (4.13)$$

Burada;

w¹: Birinci katman için bağlantı ağırlık matrisi,

x : Giriş değerleri ,

w²: Gizli katman ile çıkış katmanı arasındaki bağlantı ağırlıkları matrisi,

b¹ ve b² : Herbir katmandaki eşik değerleri,

logsig : Logaritmik sigmoid fonksiyonudur (Şekil 4.1b). Bu fonksiyonun ifadesi şu şekildedir:

$$a = \frac{1}{1 + e^{-n}} \quad (4.14)$$

ÇKA² ağının giriş-çıkış ilişkisini veren y₂ fonksiyonun ifadesi şu şekildedir:

$$y_2 = w^2 (\text{tansig}(w^1 \cdot x + b^1)) + b^2 \quad (4.15)$$

Bu ağın gizli katman aktivasyon fonksiyonu hiperbolik tanjant sigmoiddır. Bu fonksiyon,

$$a = \frac{e^n - e^{-n}}{e^n + e^{-n}} \quad (4.16)$$

eşitliği ile gösterilir.

DYSA'nın giriş-çıkış ilişkisini veren y₃ fonksiyonu dalgacık fonksiyonu kullanılarak şu şekilde ifade edilir:

$$y_3 = w^2 (\psi(w^1 \cdot x + b^1)) + b^2 \quad (4.17)$$

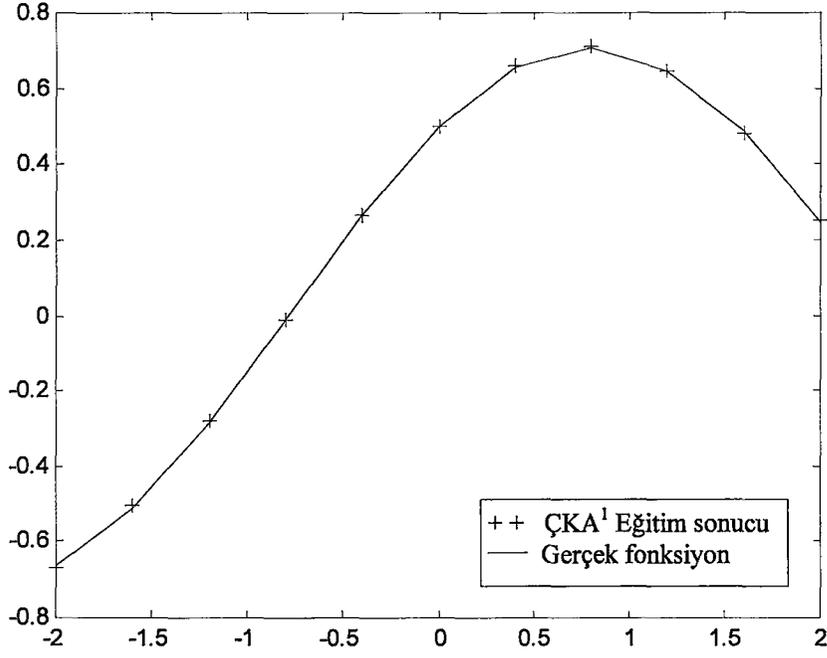
ψ : Meksika şapkası fonksiyonudur.

Öğrenme oranı sonuca yakınsamada hızı etkileyen bir faktördür. Bunun yüksek seçilmesi sonuca hızlı ulaşmayı fakat bazı durumlarda yakınsayamama gibi bir problemi ortaya çıkarmaktadır. Küçük seçildiğinde ise sonuca yakınsama daha yavaş olmaktadır. Bu etkiyi de görebilmek amacı ile $\alpha=0.05$ ve $\alpha=0.1$ öğrenme oranları için eğitim iterasyon sayıları ve süreleri Çizelge 4.3’de verilmiştir. Boyutları 1-10-1 olarak seçilmiş üç ağı eğitimi sonucunda elde edilen y_1, y_2 ve y_3 fonksiyonlarının $y = \frac{\sin(x) * \cos(x)}{2}$ fonksiyonu ile birlikte gösterilimi

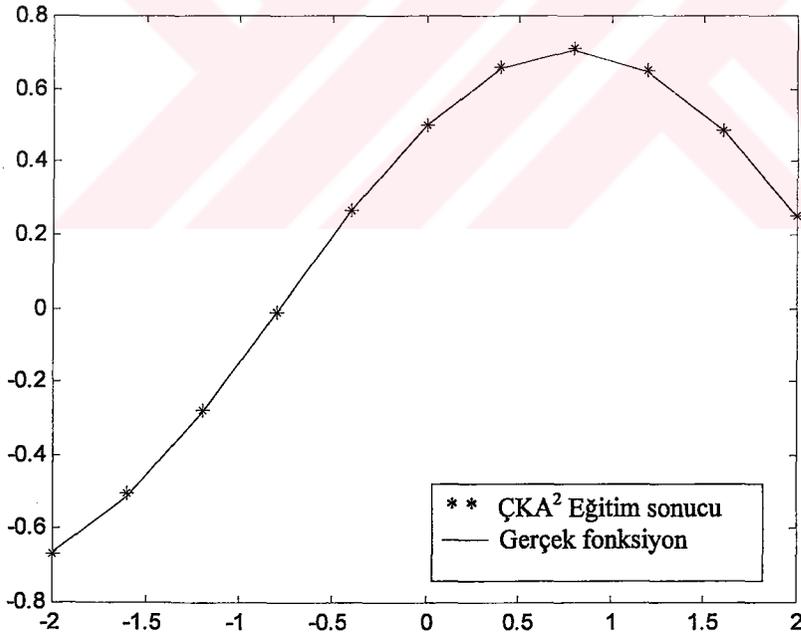
Şekil 4.11, 4.12, 4.13’de verilmiştir.

Çizelge 4.3 ÇKA¹, ÇKA² ve DYSA’nın $\alpha=0.05$ ve $\alpha=0.1$ öğrenme oranları için eğitim sonuçları

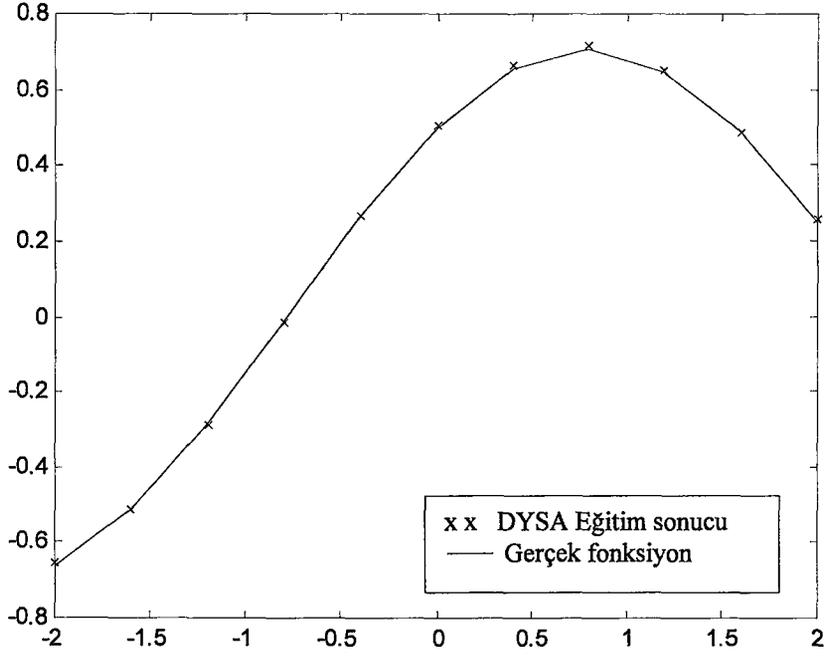
Öğrenme Oranları	$\alpha = 0.05$		$\alpha = 0.1$	
	İterasyon	Süre (s)	İterasyon	Süre(s)
ÇKA ¹	14687	1110,81	7687	502,95
ÇKA ²	3737	228,38	1621	84,47
DYSA	1346	77,33	941	54,16



Şekil 4.11 ÇKA¹'in eğitimi sonucu bulunan y_1 fonksiyonu ile orijinal y fonksiyonunun birlikte gösterimi

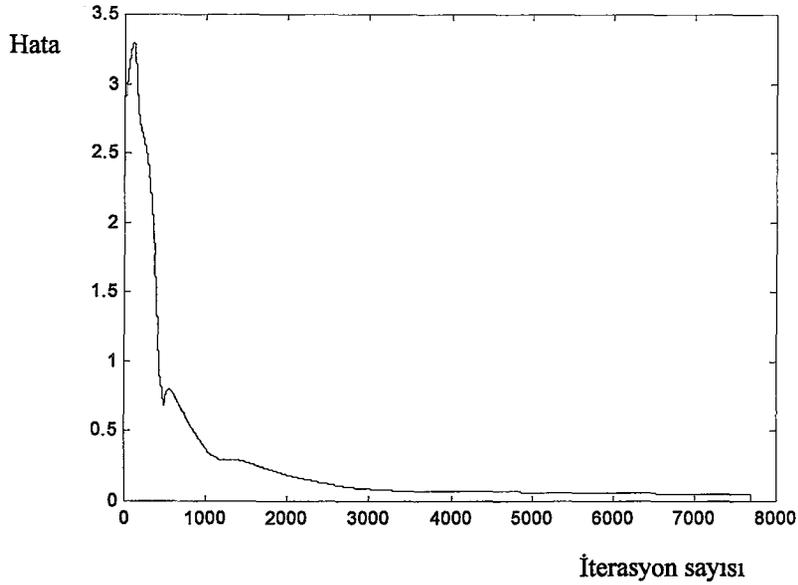


Şekil 4.12 ÇKA²'nin eğitimi sonucu bulunan y_2 fonksiyonu ile orijinal y fonksiyonunun birlikte gösterimi

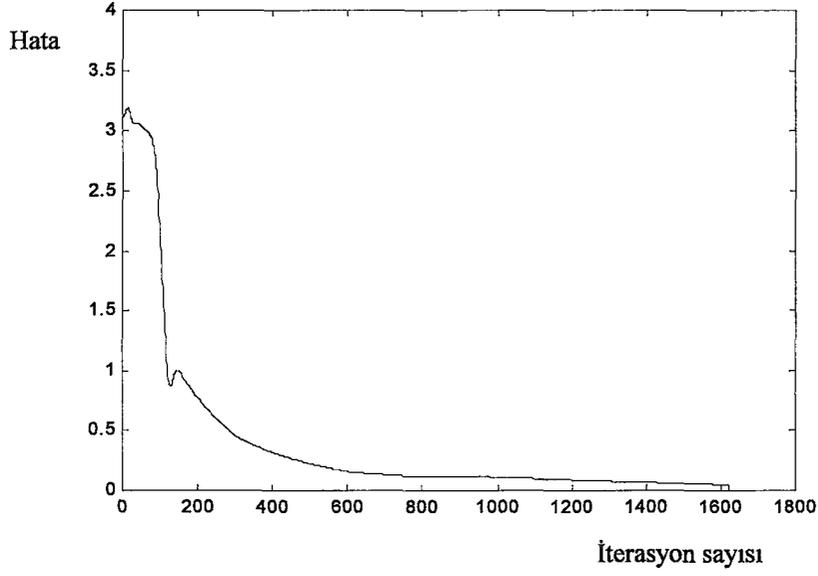


Şekil 4.13 DYSA'nın eğitimi sonucu bulunan y_3 fonksiyonu ile orijinal y fonksiyonunun birlikte gösterimi

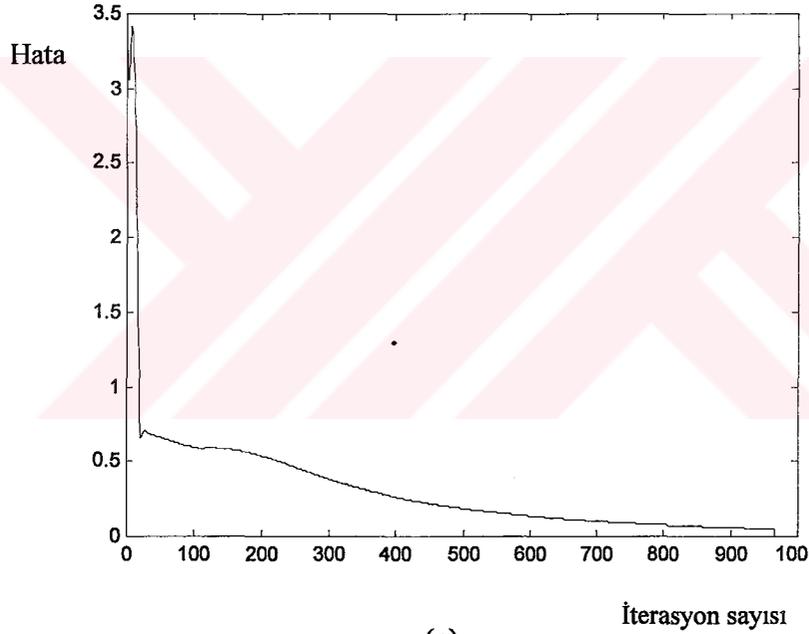
Eğitimin başlangıcında hatanın iterasyona göre değişimi hızlı bir düşüm göstermekte daha sonraki iterasyonlarda istenilen hata oranının yakalanması daha küçük adımlar ile olmaktadır. Hatanın iterasyon sayısına göre değişimi Şekil 4.14'da verilmiştir.



(a)



(b)

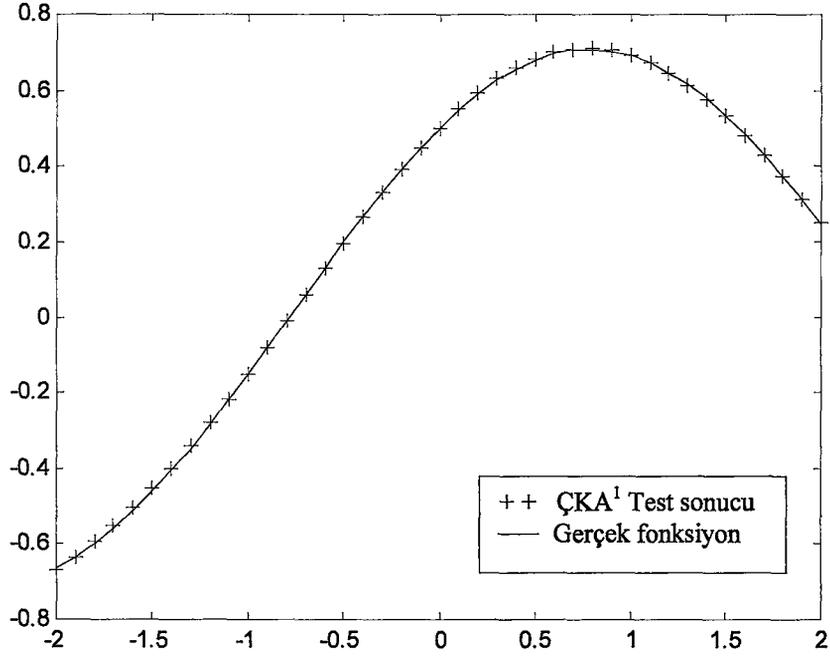


(c)

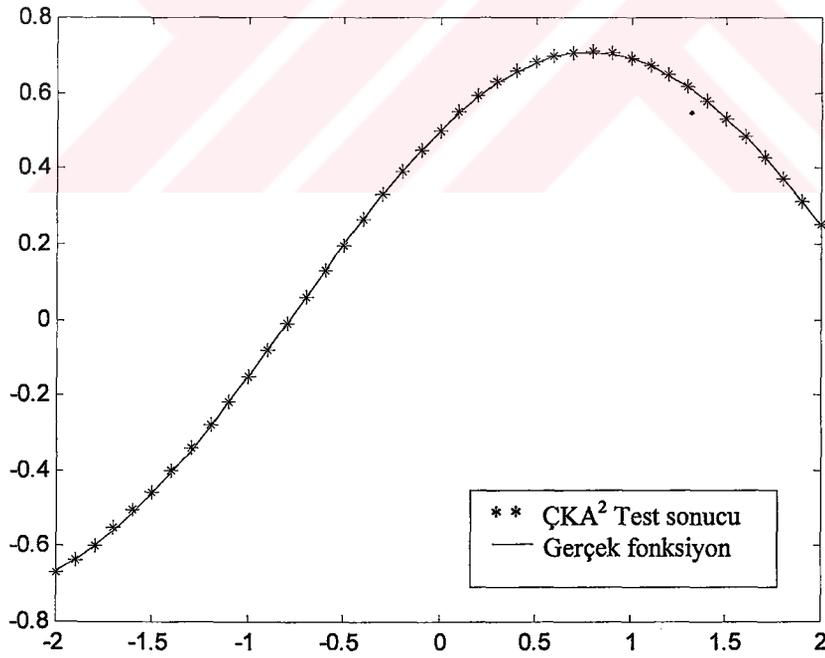
Şekil 4.14 Eğitim sonucunda hatanın iterasyon sayısına göre değişimi

a) ÇKA¹, b) ÇKA², c) DYSA

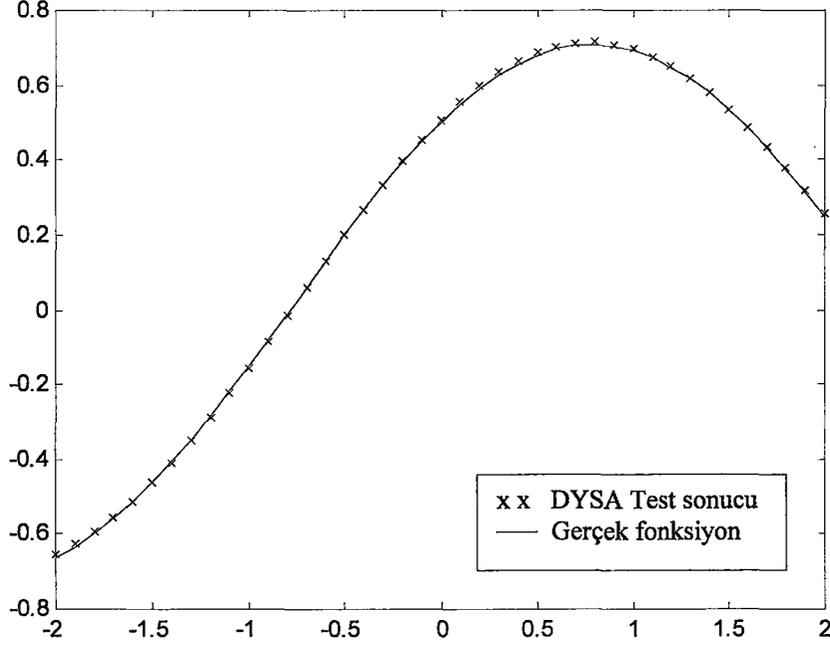
Test aşamasında x 'in $[-2,2]$ aralığındaki 0.1 aralıklı değerleri için ÇKA¹, ÇKA², DYSA'ların sonuçları orijinal y fonksiyonu ile birlikte Şekil 4.15, 4.16, 4.17'de gösterilmiştir.



Şekil 4.15 ÇKA¹'in test sonuçları ile orijinal y fonksiyonunun birlikte gösterimi



Şekil 4.16 ÇKA²'nin test sonuçları ile orijinal y fonksiyonunun birlikte gösterimi



Şekil 4.17 DYSA'nın test sonuçları ile orijinal y fonksiyonunun birlikte gösterimi

4.3.3 Aydınlık Düzeyi Hesabı

4.3.3.1 Aydınlık Düzeyi

Bir yüzeyin herhangi bir noktasındaki ortalama aydınlık düzeyi 'E', bu noktayı içine alan bir ΔS yüzeyine düşen $\Delta\phi$ ışık akısı olarak tanımlanır.

$$E = \lim_{\Delta S \rightarrow 0} \frac{\Delta\phi}{\Delta S} = \frac{d\phi}{dS} \quad (4.18)$$

Şekil 4.18'de görülen bir xy düzlemindeki A noktasının aydınlık düzeyi;

$$E = \frac{I(\alpha)}{h^2} \cdot \cos^3 \alpha \quad (4.19)$$

bağıntısı ile ifade edilir (Özkaya, 1994). Bu bağıntıda;

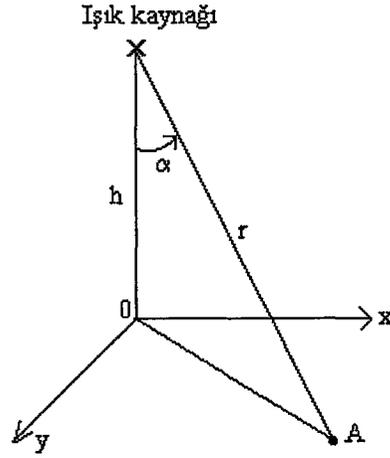
$I(\alpha)$: Işık şiddeti (Candela),

E : A noktasındaki aydınlık düzeyi (lüx)

r : Işık kaynağı ile aydınlık düzeyinin hesaplanacağı nokta arasındaki mesafe (m),

h : Işık kaynağının yerden yüksekliği,

α : Aydınlık düzeyinin hesaplanacağı noktanın içinde bulunduğu yüzeyin normali ile gelen ışığın doğrultusu arasındaki açı olarak ifade edilir .



Şekil 4.18 Aydınlık düzeyi hesaplanacak noktanın konumu

4.3.3.2 Işık Dağılım Eğrileri

Noktasal bir ışık kaynağının çeşitli doğrultulardaki ışık şiddetlerinin uç noktalarının geometrik yeri bir yüzey olup bu yüzeye ışık dağılım yüzeyi denir. Eğer kaynaktan geçen bir düzlem üzerindeki ışık şiddetlerinin uç noktaları gözönüne alınırsa bunların geometrik yeri, kaynağın ışık dağılım yüzeyi ile söz konusu düzlemin arakesitinin oluşturduğu bir eğridir ve bu eğriye ışık dağılım eğrisi adı verilir. Bu eğriler genellikle 2.5^0 , 5^0 veya 10^0 gibi sabit düşey açı aralıklarında çıkartılır(Özkaya, 1994).

Işık dağılım eğrilerinin, ölçüm yapılmayan doğrultulardaki değerlerin belirlenmesinde çeşitli interpolasyon metodları kullanılmaktadır. Lineer interpolasyon, lineeer-cubic spline interpolasyonu, cubic-spline interpolasyonu, 3.dereceden polinomla interpolasyon ve cos polinomu bu metodlara örnek olarak verilebilir (Mısır vd.,1993). Her bir metodun diğerine karşı, değerlerin tespit aşaması, ölçüm sonuçlarına uygunluk, kullanım ve pratiklik açısından avantaj ve dezavantajları vardır.

Bu yöntemlerden lineer interpolasyon; iki nokta arasındaki değişimin lineer kabul edilmesi prensibine dayanır. Cubic spline interpolasyonu, verilen data noktalarından her bir data noktasına gelirken sağdan ve soldan eğimleri eşit kabul ederek, bu noktaları sağlayan spline

eğrileri geçirilmesine dayanır. Trigonometrik cos polinomunda giriş dizisi eşit aralıklı olmak zorundadır. Fourier serisi açılımdaki gibi giriş dizisine karşılık katsayılar hesaplanır ve katsayılar bir cos polinomunun katsayıları olarak kullanılır. Bu metodda sağdan ve soldan yaklaşımlarda türevlerin eşitliği sınırlaması benimsenmiştir. 3.dereceden polinomla yapılan interpolasyonda ise kullanılan 3.dereceden polinomda katsayıların belirlenmesinde başlangıç ve bitiş noktalarında türev sıfır, ara noktalarda ise türev bir önceki noktalardaki değerle bir sonraki noktadaki değer farklarının aralığa bölümüne eşit alınır (Mısır vd., 1993)

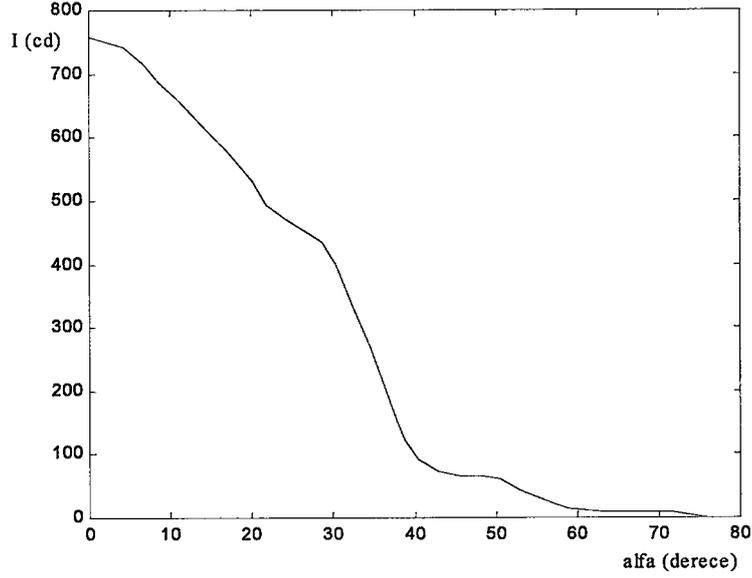
Yapay sinir ağları da yeni bir yöntem olarak ışık dağılım eğrilerinin bulunmasında son zamanlarda kullanılmaktadır. Bir önceki bölümde anlatılan özellikler YSA'ların bu alanda da başarılı sonuçlar vermesine olanak tanımaktadır.

Bu uygulamada, deneysel sonuçlardan yola çıkarak ışık dağılım eğrilerinin bulunmasında yapay sinir ağlarının kullanımı ele alınmıştır. Bulunan bu eğri yardımı ile aydınlık düzeyi hesabı yapılmıştır. Kullanılan ÇKA¹, ÇKA² ve DYSA yapılarının sonuçları karşılaştırılmalı olarak incelenmiştir.

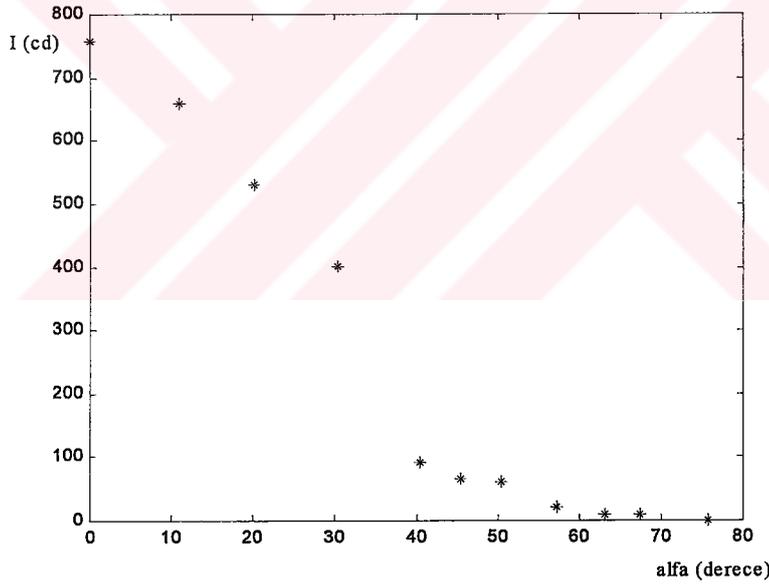
4.3.3.3 Aydınlık Düzeyi Hesabının Yapay Sinir Ağları Kullanılarak Gerçeklenmesi

Aydınlık düzeyi hesabında, $I(\alpha)$ değerlerinin yüzeye ait her bir nokta için bilinmesi gerekmektedir. Ölçüm yapılmayan noktalara ait ışık şiddetlerinin bulunması tüm yüzeye ait ışık şiddeti değerlerini veren eğrinin matematiksel ifadesinin elde edilmesi ile mümkün olabilmektedir. Bu amaçla ölçülen $I(\alpha)$ değerleri kullanılarak yapay sinir ağlarının eğitimi yapılır. Bu eğitim sonucu elde edilen giriş-çıkış ilişkisi ışık dağılım eğrilerinin matematiksel ifadesine karşılık düşmektedir.

Şekil 4.19'da bir aydınlatma armatüründen deneysel uygulamalar sonucu elde edilmiş 19 adet $I(\alpha)$ ışık şiddeti verilerinden yola çıkılarak çizilmiş ışık dağılım eğrisi görülmektedir. Bu verilerden 11 tanesi eğitime işlemi için kullanılmıştır (Şekil 4.20). Alfa açıları ağa giriş verisi olarak verilmiş, alfa açılara karşılık gelen ışık şiddeti değerleri de hedef değerler olarak belirlenmiştir.



Şekil 4.19 İncelenen ışık kaynağının ışık dağılım eğrisi

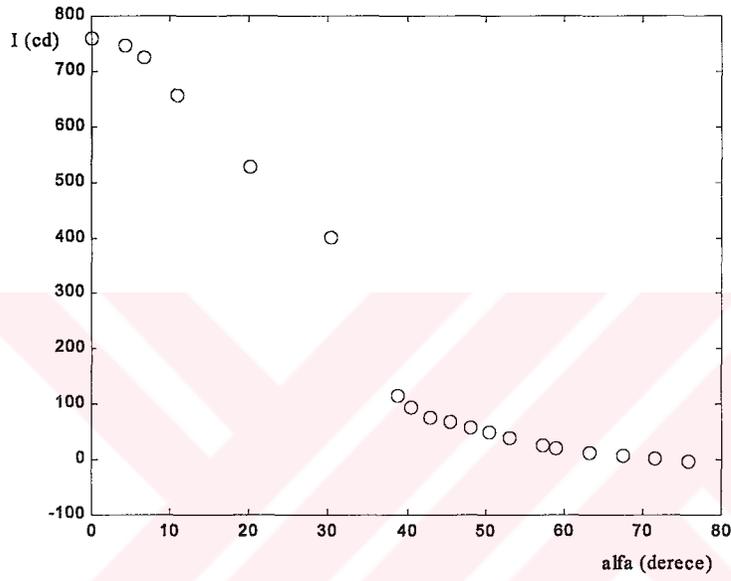


Şekil 4.20 Eğitim kümesi olarak kullanılan 11 noktanın aydınlatma şiddetleri

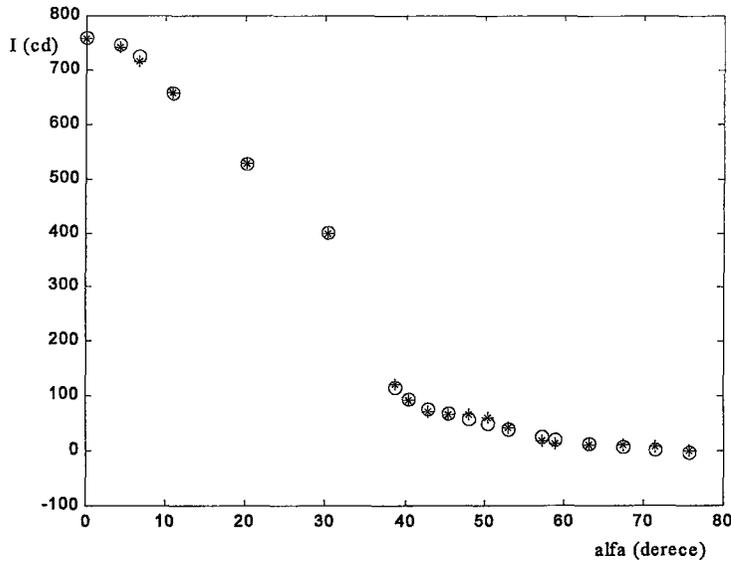
DYSA ve ÇKA ağlarının eğitiminde hata değeri, öğrenme oranı ve düğüm sayıları eşit alınmıştır. Eğitim sonucunda girilen nokta sayısına göre iterasyon sayıları Çizelge 4.4'de verilmiştir. DYSA'nın matematiksel ifadesinin sonuçları ile deneysel sonuçlar test aşamasında karşılaştırılmıştır. Şekil 4.21 ve Şekil 4.22 'de görülen bu sonuçlarda hata %3-4 civarında olmuştur.

Çizelge 4.4 Eğitim aşaması iterasyon sonuçları

Eğitim için girilen veri sayısı	2	3	4	5	6	11
ÇKA ¹	150	2548	3465	13540	22501	157023
ÇKA ²	95	1659	2565	9496	14566	114547
DYSA	4	350	1757	1656	5658	39548

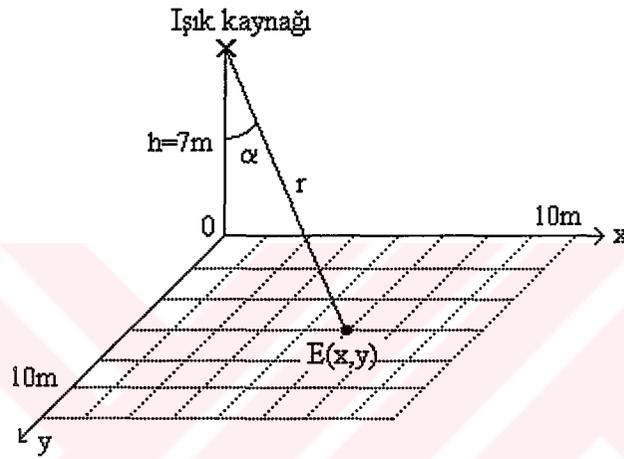


Şekil 4.21 DYSA test sonuçları



Şekil 4.22 DYSA test sonuçları ile orjinal verilerin birlikte gösterilimi

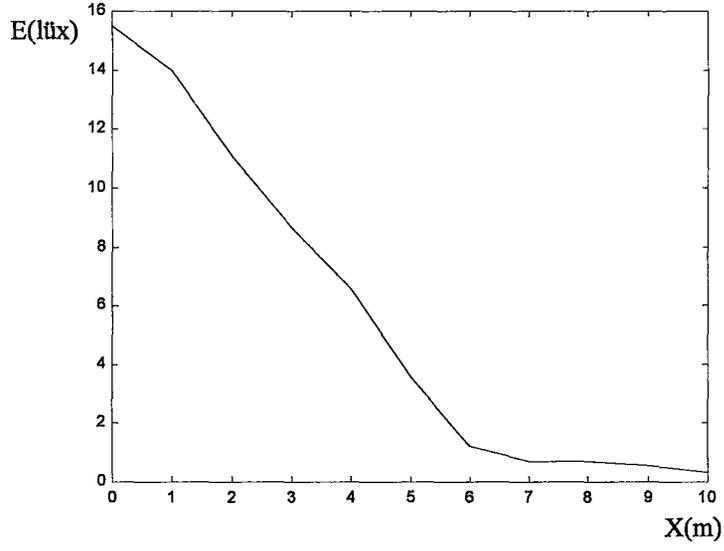
Üç ağda da hata oranı eşit seçildiğinden dolayı bulunan sonuçlar ortalama olarak aynıdır. Buradaki farklılık Çizelge 4.4'de de görüleceği üzere sonuca ulaşmaktaki hızlardır. Eğitim sonucunda bulunan $I(\alpha)$ fonksiyonu kullanılarak noktasal aydınlatma bağıntısı yardımıyla Şekil 4.23'de gösterilen x-y düzlemi üzerindeki noktaların aydınlık düzeyleri hesaplanmıştır. Bu düzlemde aydınlatması yapılacak bölge 10x10 m boyutlarında ve dönele simetrik ışık kaynağı 7m yüksekliğindedir. Hesaplanan aydınlık düzeyi değerleri Çizelge 4.5'de verilmiştir. Bu değerler kullanılarak x eksenini üzerindeki ($y=0$) noktalarının aydınlık düzeylerinin değişimi Şekil 4.24'de görülmektedir.



Şekil 4.23 Aydınlık düzeyleri hesaplanan noktalar

Çizelge 4.5 $E(x,y)$ aydınlık düzeyleri

(x,y) [m]	(0,0)	(0,5)	(0,10)	(3,3)	(3,5)	(3,10)	(5,5)	(5,7)	(5,10)	(7,7)	(10,10)
$E(x,y)$ [lüx]	15.5	2,73	0.14	4.82	1.04	0.09	0.42	0.33	0.04	0.15	0.00



Şekil 4.24 x-ekseni üzerindeki noktaların aydınlık düzeyleri

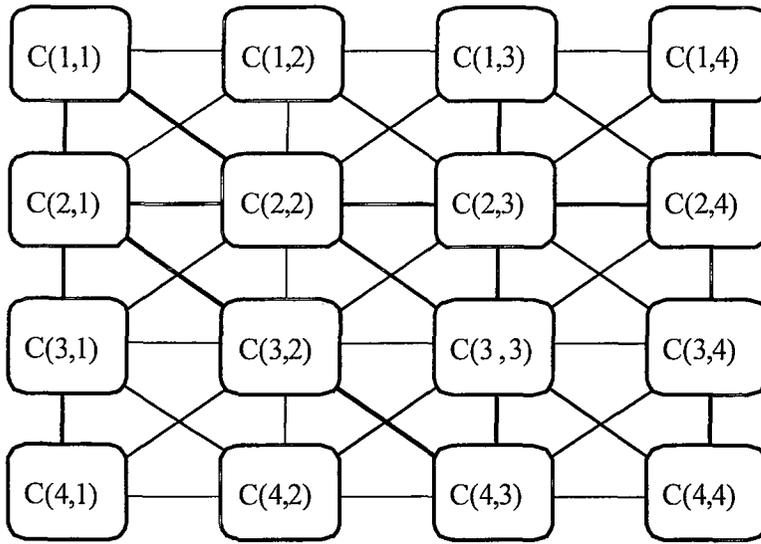


5. HÜCRESEL YAPAY SİNİR AĞI

Dinamik yapay sinir ağlarının özel bir çeşidi olan hücresel yapay sinir ağı (HYSA), iki boyutlu bir dizi oluşturacak şekilde sıralanmış hücrelerden meydana gelmiştir. Hücre yapılarındaki ağırlık katsayı şablonları ve giriş kümesinin çıkış ile değişmesi HYSA ile ileri beslemeli ağlar (İBA) arasındaki en önemli farklılıklardır. Hücrelerin ağırlık katsayılarının çalışılan düzlem üzerinde değişmez bir bağlantı ağı oluşturması ve iki boyutlu filtre yapılarına benzemesi, HYSA'nın görüntü işleme ve örüntü tanıma konularında başarılı bir şekilde kullanılmasına olanak sağlamıştır. Görüntü verile sayılarının çok büyük rakamlar ile ifade edilebilmesine karşılık HYSA, görüntü işlemede çok hızlı bir şekilde işlem yapabileme özelliğine sahiptir. Bu özellik gerçek zamanda görüntü işlemede büyük öneme sahiptir. Ön işleme elemanı olarak görüntü özellik çıkarımında HYSA'nın kullanılabilmesi ayrıca önemli bir kullanım alanıdır. Aynı zamanda, yerel bağlantı özelliği sayesinde kolaylıkla tümleşik devre olarak da gerçekleştirilebilmektedir.

5.1 Hücresel Yapay Sinir Ağı Mimarisi

İleri yönlü yapay sinir ağlarının aksine buradaki her hücre yakın komşuluğundaki hücrelerle belli bir komşuluk ilişkisi altında bağlantı halindedir. Şekil 5.1 her bir hücrenin sadece çevresindeki hücrelerle bağlantı halinde olduğu 4x4 boyutunda bir hücresel yapay sinir ağını göstermektedir (Chua, 1988).



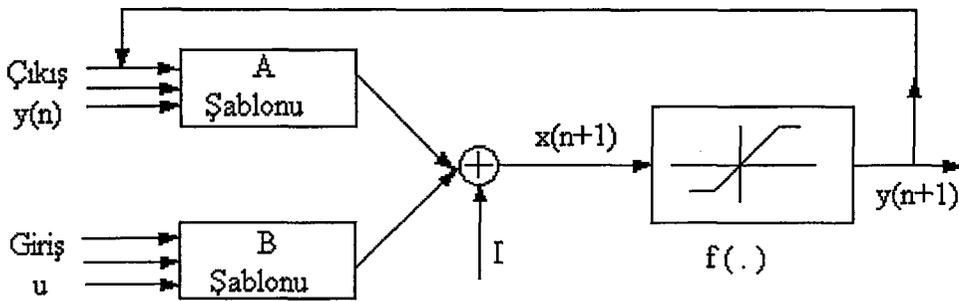
Şekil 5.1 4x4 Boyutunda bir hücresel yapay sinir ağı gösterimi.

Bir hücreyel yapay sinir ağının görüntü işlemedeki temel fonksiyonu herhangi bir giriş görüntüsünü istenilen amaca uygun olarak bir çıkış görüntüsüne dönüştürmesidir. Burada çıkış görüntüsü hücreyel yapay sinir ağları ilk haliyle ele alındığında her piksel (nokta) değeri -1 ve $+1$ olacak şekilde sınırlandırılır. Ancak buna karşılık giriş görüntüleri uygun gerilim değerleri de sağlandıktan sonra, çoklu gri seviyelerine de sahip olabilirler. Verilen bir giriş görüntüsü ile başlatılan veya sürülen herhangi bir geçici rejim sonrasında, hücreyel yapay sinir ağından geçirilmiş görüntü, gerekli koşullar sağlandığı takdirde her zaman bir kararlı durum sabit noktasına yakınsamaktadır.

Görüntü işlemede hücreyel yapay sinir ağlarında genel olarak yapılan işlem, verilen bir giriş görüntüsünün doğrusal olmayan ve dinamik bir işlemde geçirilerek çıkış görüntüsünün oluşturulmasıdır. Yapının dinamik olmasından dolayı istenilen kararlı görüntü durumu elde edilene kadar çıkış görüntüsü her zaman aralığında sürekli değişim göstermektedir. Hücreyel yapay sinir ağlarının komşuluk düzenindeki bu yapıları özellikle tümleşik devre gerçeklemlerinde büyük kolaylıklar sağlamıştır.

5.2 Hücre Yapıları

Hücreyel yapay sinir ağlarındaki her bir hücre ağırlıklı toplama yapan doğrusal bir giriş birimi, doğrusal dinamik bir ara birim ve n parçalı (genellikle üç parçalı) orjine göre simetrik bir çıkış biriminden oluşan mimariye sahiptir (Şekil 5.2).



Şekil 5.2 Bir hücrenin dinamik yapısı

Bu mimarinin ilk ortaya çıkışı devresel bir gösterim ile olmuştur. Bu devredeki hücrelerin herbiri doğrusal ve doğrusal olmayan dirençler, kapasiteler, akım ve gerilim kontrollü kaynaklar içerirler. Teorik açıdan hücreyel yapay sinir ağları çok boyutlu olarak

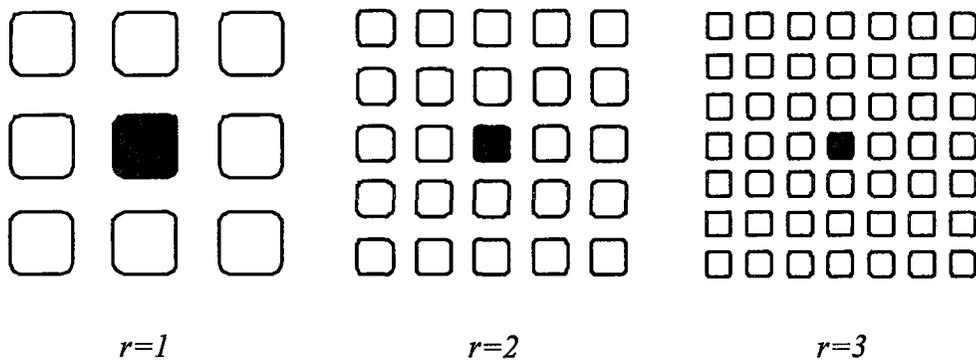
tanımlanabilmelerine rağmen tez boyunca yapılan çalışmalarda özellikle görüntü işleme uygulamaları üzerinde durulduğundan burada ele alınan hücresel yapay sinir ağları iki boyutlu olarak kullanılmıştır. Ancak istenildiği takdirde elde edilen sonuçlar kolaylıkla daha yüksek boyutlu durumlara genelleştirilebilir.

5.3 Hücresel Yapay Sinir Ağlarında Komşuluk İlişkisi

M satır ve N kolondan oluşan bir $M \times N$ 'lik hücresel yapay sinir ağı ele alalım. Böyle bir yapıda i. Satır ve j. kolona (i,j) hücresi adını verip $C(i,j)$ olarak ifade edeceğiz. Burada herhangi bir $C(i,j)$ hücresinin r-komşuluğu şu şekilde tanımlanır.

$$N_r(i,j) = \{C(k,l) \mid \max(|i-k|, |j-l|) \leq r, \quad 1 \leq i \leq M; 1 \leq j \leq N \} \quad (5.1)$$

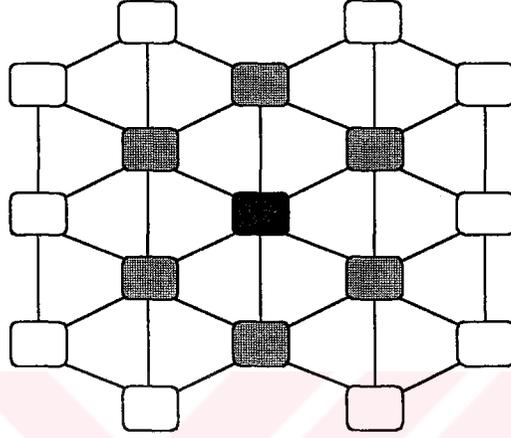
Burada komşuluğu gösteren r pozitif bir tamsayıdır ve her bir hücrenin kendisinden ne kadar uzaklıktaki hücreler tarafından doğrudan etkileneceğine işaret eder. Şekil 5.3'de de görülebileceği gibi $r=1$ komşuluğunda yapı içerisindeki her bir hücre sadece çevresindeki hücreler tarafından etkilenirken (buradaki etkilenme doğrudan bir etkilenmeyi vurgulamaktadır, gerçekte bu yapıdaki her bir hücre yapının hücre sayısına bağlı olarak belli bir zaman veya çevrim sonunda birbirlerini yayılım etkisi sonucu etkileyebilmektedirler) $r=2$ ve $r=3$ komşuluklarında hücreler kendilerinden iki ve üç hücre uzaklıklarındaki hücreler tarafından da etkilenebileceğini göstermektedir.



Şekil 5.3 Hücresel yapay sinir ağlarında komşuluk

$r=1$, $r=2$ ve $r=3$ olmak üzere üç farklı komşuluk durumunun bulunduğu bu gösterimlerde genellikle $r=1$, $r=2$ ve $r=3$ komşuluklarına sırasıyla “3x3”, “5x5” ve “7x7” komşulukları da

denir. Bir r -komşuluğu içerisinde $(2r+1)(2r+1)$ tane hücre bulunur. Komşuluk aynı zamanda simetri özelliğine de sahiptir. Yani $C(k,l) \in N_r(i,j)$ ise $C(i,j) \in N_r(k,l)$ dir. Hücrelerin bu şekilde karesel olarak sıralandığı bir yapının yanı sıra aynı komşuluk ilişkileri içerisinde ve karesel olmayan formatta da sıralanmaları mümkündür. Şekil 5.4'te hexadiagonal olarak sıralanmış iki boyutlu bir hücresel yapay sinir ağı yapısı gösterilmiştir.



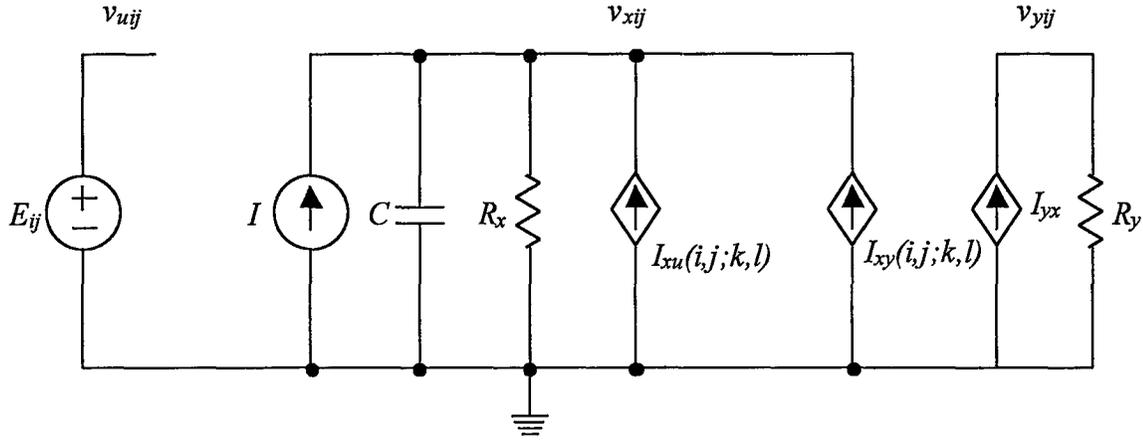
Şekil 5.4 $r=1$ Komşuluğunda heksagonal yapıya sahip hücresel yapay sinir ağı

5.4 Hücresel Yapay Sinir Ağının Devresel Gösterimi

Hücresel yapay sinir ağındaki bir hücreye karşılık gelen devresel eşdeğer Şekil 5.5' de gösterilmiştir. Hücresel yapay sinir ağının herhangi bir $C(i,j)$ hücresine karşılık gelen bu devrede u giriş, x durum ve y çıkışa karşılık gelmektedir. Bu $C(i,j)$ hücresine ait v_{xij} durum geriliminin başlangıç koşulu ile giriş gerilimi olan v_{uij} 'nin 1 den küçük veya eşit olduğu kabul edilmiştir. v_{yij} ise çıkış gerilimidir.

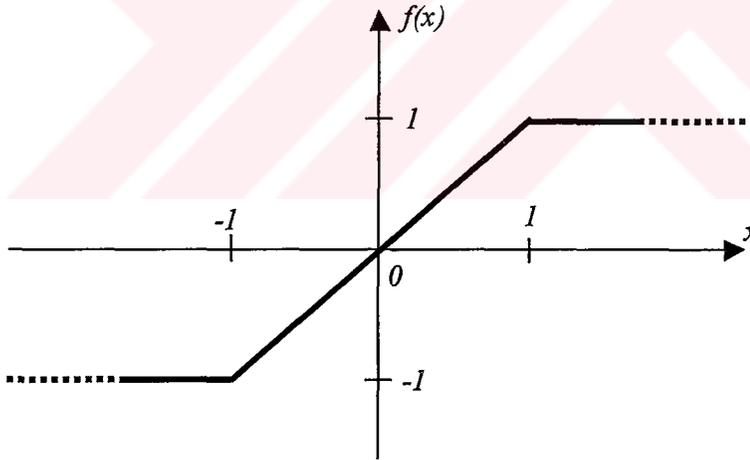
Şekil 5.5'deki devrede $C(i,j)$ hücresi bir bağımsız gerilim kaynağı E_{ij} , bir bağımsız akım kaynağı I , bir lineer kapasite C , iki lineer direnç R_x ve R_y , komşu hücrelerin iki katı kadar sayıda olan ve giriş kontrol gerilimi v_{ukl} ile çıkış kontrol gerilimi v_{ykl} tarafından geribesleme olarak kontrol edilen lineer gerilim kontrollü akım kaynaklarından meydana geldiği görülür. Burada $I_{xy}(i,j;k,l)$ ve $I_{xu}(i,j;k,l)$ gerilim kontrollü akım kaynaklarının karakteristikleri $C(k,l) \in N_r(i,j)$ komşuluğu altında $I_{xy}(i,j;k,l) = A(i,j;k,l) v_{ykl}$ ve $I_{xu}(i,j;k,l) = B(i,j;k,l) v_{ukl}$ olarak ifade edilirler. Her hücre içerisindeki tek lineer olmayan eleman parça-parça doğrusal $I_{yx} = (1/R_y) f(v_{xij})$ karaktersitiğine sahip olan gerilim kontrollü akım kaynağıdır. $f(.)$

fonksiyonu Şekil 5.6'da gösterilmiştir.



Şekil 5.5 Bir hücre yapısının devresel olarak gösterilmesi

Bu devresel yapıdaki tüm parça-parça doğrusal fonksiyonlar işlemsel kuvvetlendiricili devreler yardımıyla kolaylıkla gerçekleştirilebilirler.



Şekil 5.6 Parça-parça doğrusal çıkış karakteristiği

Kirchoff gerilimler ve akımlar yasası uygulanarak bu hücre devresinin eşitliği aşağıda gösterildiği gibi kolayca türetilir.

Durum eşitliği:

$$C \frac{dv_{xij}(t)}{dt} = -\frac{1}{R_x} v_{xij}(t) + \sum_{C(k,l) \in N_r(i,j)} A(i,j;k,l) v_{ykl}(t) + \sum_{C(k,l) \in N_r(i,j)} B(i,j;k,l) v_{ukl} + I, \quad (5.2a)$$

$$1 \leq i \leq M; 1 \leq j \leq N.$$

Çıkış eşitliği:

$$v_{yij}(t) = \frac{1}{2} \left(|v_{xij}(t) + 1| - |v_{xij}(t) - 1| \right), \quad 1 \leq i \leq M; 1 \leq j \leq N. \quad (5.2b)$$

Giriş eşitliği:

$$v_{uij}(t) = E_{ij}, \quad 1 \leq i \leq M; 1 \leq j \leq N. \quad (5.2c)$$

Kısıtlama durumları:

$$|v_{xij}(0)| \leq 1, \quad 1 \leq i \leq M; 1 \leq j \leq N. \quad (5.2d)$$

$$|v_{uij}| \leq 1, \quad 1 \leq i \leq M; 1 \leq j \leq N. \quad (5.2e)$$

Parametrik kabuller:

$$A(i,j;k,l) = A(k,l;i,j), \quad 1 \leq i \leq M; 1 \leq j \leq N. \quad (5.2f)$$

$$C > 0, R_x > 0 \quad (5.2g)$$

Buraya kadar anlatılanların ışığı altında ortaya çıkanları şu şekilde sıralayabiliriz:

Bir hücreyel yapay sinir ağındaki tüm merkezi hücreler aynı devre yapısı ve değerlerine sahiptirler. Bu şekilde tanımlanan hücreyel yapay sinir ağ yapıları doğrusal olmayan bir denklem takımı ile karakterize edilirler.

Hücreyel yapay sinir ağındaki bir hücrenin dinamiklerini çıkış geribeslemesinin etkisini belirleyen $A(i,j;k,l)$ parametresi ile girişin kontrol etkisini belirleyen $B(i,j;k,l)$ parametreleri oluşturur. Bu parametreler ayrıca $A(i,j;k,l)$ geri-besleme ağırlık katsayısı ve $B(i,j;k,l)$ giriş ağırlık katsayısı olarak da adlandırılırlar.

5.5 Diferansiyel Denklemlerin Fark Denklemleri Olarak Gösterilmesi

Hücrel yapay sinir ağının görüntü işlemede uygulamasını görmek amacıyla ilk olarak (5.2a) diferansiyel denklemini, fark denklemi olarak yazalım. Bunun için h sabit bir zaman adımı olmak üzere $t=nh$ yazılacak olursa, $v_{xij}(t)$ ile ifade edilen diferansiyel denklemi fark denklemi biçiminde elde edilebilir.

$$\frac{C}{h} [v_{xij}((n+1)h) - v_{xij}(nh)] = -\frac{1}{R_x} v_{xij}(nh) + \sum_{C(k,l) \in N_r(t,j)} A(i,j;k,l) v_{ykl}(nh) + \sum_{C(k,l) \in N_r(i,j)} B(i,j;k,l) v_{ukl} + I, \quad (5.3a)$$

$1 \leq i \leq M; 1 \leq j \leq N.$

Çıkış denkleminde de aynı işlemi gerçekleştirecek olursak:

$$v_{yij}(nh) = \frac{1}{2} (|v_{xij}(nh) + 1| - |v_{xij}(nh) - 1|) \equiv f(v_{xij}(nh)), \quad 1 \leq i \leq M; 1 \leq j \leq N. \quad (5.3b)$$

elde ederiz. (5.3a) denkleminde

$$I_{ij} = \sum_{C(k,l) \in N_r(i,j)} B(i,j;k,l) v_{ukl} + I, \quad 1 \leq i \leq M; 1 \leq j \leq N \quad (5.4)$$

alınarak eşitlik şu şekilde yeniden yazılabilir.

$$v_{xij}(n+1) = v_{xij}(n) + \frac{h}{C} \left[\frac{-1}{R_x} v_{xij}(n) + \sum_{C(k,l) \in N_r(i,j)} A(i,j;k,l) v_{ykl}(n) + I_{ij} \right] \quad (5.5)$$

$1 \leq i \leq M; 1 \leq j \leq N$

Burada basitlik açısından zaman sabiti h “ nh ” ifadesinden çıkarılmıştır; Örneğin $v_{xij}(n) \equiv v_{xij}(nh)$ ve $v_{yij}(n) \equiv v_{yij}(nh)$ gibi $v_{ykl}(n)$ için (5.3b) eşitliğini (5.5)’de yerine koyarsak,

$$v_{xij}(n+1) = v_{xij}(n) + \frac{h}{C} \left[\frac{-1}{R_x} v_{xij}(n) + \sum_{C(k,l) \in N_r(i,j)} A(i,j;k,l) f(v_{ykl}(n)) + I_{ij} \right] \quad (5.6)$$

$1 \leq i \leq M; 1 \leq j \leq N$

eşitliğini elde ederiz.

Son olarak elde edilen bu (5.6) eşitliği, $v_{xij}(n)$ ile ifade edilen bir görüntünün, $v_{xij}(n+1)$ ile ifade edilen başka bir görüntüye dönüşümünde kullanılan iki boyutlu bir filtre gibi

düşünülebilir. Görüntü işlemede filtre, genellikle çalışılan uzamda değişmezdir, yani tüm i, j, k, l değerleri için $A(i, j; k, l) = A(i - k, j - l)$ 'dır.

5.6 Hücresel Yapay Sinir Ağlarında Kararlılık

Hücresel yapay sinir ağlarının halen devam eden araştırma konularından birisi de kararlılık problemi (Zou vd.,1991; Vanderwalle vd., 1993). Başka bir deyişle hücresel yapay sinir ağ çıkışlarının geçici rejimden sonra hangi koşullar altında sabit kararlı çıkış değerlerine ulaşacağıdır. Bu durumu;

$$\lim_{t \rightarrow \infty} v_{xij}(t) = \text{sabit}, \quad 1 \leq i \leq M; 1 \leq j \leq N \quad (5.7)$$

veya geçici rejim sonrasında durum görüntüsünün sabit bir değere ulaşması durumunu göz önüne alarak

$$\lim_{t \rightarrow \infty} \frac{dv_{xij}(t)}{dt} = 0, \quad 1 \leq i \leq M; 1 \leq j \leq N \quad (5.8)$$

şeklinde de ifade edebiliriz.

Bu konuda yapılan çalışmalar göstermiştir ki; A geri besleme ağırlık katsayı matrisinin simetrik olması durumunda devre parametrelerinin,

$$A(i, j; i, j) > \frac{1}{R_x} \quad (5.9)$$

koşulunu sağlaması durumunda

$$\lim_{t \rightarrow \infty} |v_{xij}(t)| \geq 1, \quad 1 \leq i \leq M; 1 \leq j \leq N \quad (5.10)$$

veya eşdeğeri

$$\lim_{t \rightarrow \infty} v_{yij}(t) = \pm 1, \quad 1 \leq i \leq M; 1 \leq j \leq N \quad (5.11)$$

koşulları sağlanmış olur.

Bu da hücresel yapay sinir ağı için devrenin osilasyon yapmayacağını veya en azından kaotik bir duruma geçmeyeceğini göstermesi açısından oldukça önem taşımaktadır. Bu durum hücresel sinir ağının çıkışlarının sadece ikili değerlerden oluşacağını garanti etmektedir.

5.7 Hücresel Yapay Sinir Ağının Sürekli Zaman Analizi

Hücresel yapay sinir ağı dinamik bir ağ olduğundan durum ve buna lineer olmayan bir fonksiyonla bağlı olan çıkış, sürekli bir değişim içerisindedir. Hücresel yapay sinir ağındaki bu görüntü dönüşümünün nasıl çalıştığını daha rahat anlayabilmek için (5.2a) eşitliğini integral formunda aşağıda gösterildiği gibi tekrar yazalım:

$$v_{xij}(t) = v_{xij}(0) + \frac{1}{C} \int_0^t \left[\frac{-1}{R_x} v_{xij}(\tau) + f_{ij}(\tau) + g_{ij}(u) + I \right] d\tau, \quad 1 \leq i \leq M; 1 \leq j \leq N \quad (5.12)$$

Burada,

$$f_{ij}(t) = \sum_{C(k,l) \in N_r(i,j)} A(i, j; k, l) v_{ykl}(t) \quad (5.13a)$$

ve

$$g_{ij}(u) = \sum_{C(k,l) \in N_r(i,j)} B(i, j; k, l) v_{ukl} \quad (5.13b)$$

olarak yeniden düzenlenmişlerdir.

Burada yazılan (5.12) eşitliğinden açıkça görülmektedir ki $v_{xij}(t)$, görüntünün herhangi bir t anındaki durumunu karşılık düşmektedir. Bu durum başlangıç koşulu olarak verilen görüntü $v_{xij}(0)$ ve hücresel yapay sinir ağının dinamik kurallarına bağlıdır. Böylece hücresel yapay sinir ağı, bir başlangıç görüntüsünün herhangi bir t anındaki dinamik dönüşümünü elde etmek için kullanılabilir. Özel olarak burada $t \rightarrow \infty$ olması durumunda, durum değişkeni tam kararlı durumda v_{xij} bir sabite ve çıkış v_{yij} ise $+1$ ve -1 değerlerinden herhangi birisine gitmektedir. Kararlılık koşullarının sağlanmaması durumunda ise osilasyon ve kaotik durumları ortaya çıkmaktadır.

6. DALGACIK HÜCRESEL YAPAY SİNİR AĞI

Dinamik ağ yapısına sahip olan HYSAs'larının eğitimi için çeşitli yöntemlerin geliştirildiği giriş bölümünde anlatılmıştır. Bu yöntemler uygulama alanlarına göre optimum sonuçlar veren öğrenme algoritmalarından oluşmaktadır. Görüntü sıkıştırma, bölütleme ve kodlama bu uygulama alanlarına örnek olarak verilebilir.

Bu tez çalışmasının amacı HYSAs için yeni bir öğrenme algoritmasının geliştirilmesidir. Bu amaca ulaşmadaki iki önemli başlık dalgacık teorisinden ve ileri beslemeli ağlarda (İBA) kullanımı bulunan öğrenme algoritmalarından yararlanmaktır. Bu konudaki araştırmalar sonucunda dalgacık fonksiyonları ile İBA'da çok geniş uygulama alanına sahip geriye yayılım algoritmasının (Backpropagation) kullanımı üzerinde yoğunlaşmıştır.

Bu iki yöntemin HYSAs'na uyarlanması sonucunda elde edilen yeni öğrenme algoritması *Dalgacık Öğrenme Algoritması (DÖA)* olarak adlandırılmıştır. Bu öğrenme algoritmasının kullanımı ile daha küçük boyutlarda HYSAs mimarisi oluşturulmuştur. Bu mimari *Dalgacık Hücresel Yapay Sinir Ağı (DHYSAs)* olarak adlandırılmıştır. Bu yeni ağ yapısı ve öğrenme algoritması ile sentetik ve gerçek görüntü işleme uygulamaları, tıbbi görüntülerin bölütlenmesi, jeofizik ve arkeolojik görüntülerin analizi yapılmış ve klasik yöntemler ile karşılaştırılmıştır.

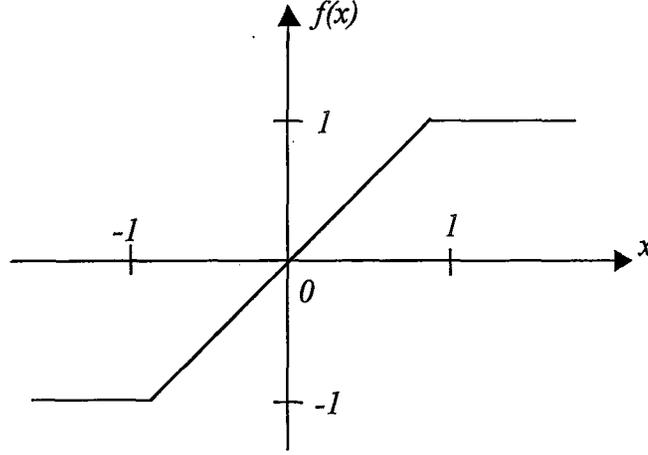
6.1 Dalgacık Öğrenme Algoritması

HYSAs ile İBA arasındaki yapı farklılıklarından dolayı, geriye yayılım algoritmasının HYSAs'da kullanılabilmesi için birtakım değişikliklerin yapılması gerekmektedir. Değişiklik yapılması gereken kısımlar şu şekilde sıralanabilir:

Sürekli fonksiyon - Geriye yayılım algoritmasında aktivasyon fonksiyonunun türevi alındığından dolayı bu fonksiyonların sürekli olma zorunluluğu vardır. HYSAs'nın aktivasyon fonksiyonu ise sürekli fonksiyon değildir (Şekil 6.1).

İleri yayılım yöntemi - İleri yayılım sürecinde iki farklı yöntem uygulanabilmektedir. Algoritmanın oluşturulmasında aşağıdaki iki yöntemden en uygununun seçimi yapılmalıdır.

- 1) Ağın yapısını İBA yapısına benzetmek
- 2) Algoritma içinde HYSAs'nın kendi yapısını kullanmak



Şekil 6.1 HYSA aktivasyon fonksiyonu

Giriş değeri - Adımsal düşüm formülünün yeni ağırlıkları veren eşitliğinde giriş değerleri kullanılmaktadır (Eşitlik 6.1). HYSA’nda giriş değerleri çıkışla birlikte değiştiğinden dolayı yakınsamama problemi ortaya çıkmaktadır.

$$\omega_{i,j}^m(k+1) = \omega_{i,j}^m(k) - \alpha s_i^m a_j^{m-1} \quad (6.1)$$

Matris boyutları - HYSA yapısında kullanılan A ve B şablonları (ağırlık katsayıları) 3x3, 9x9 gibi küçük boyutlardadır. Görüntü verileri ise büyük boyutlu matrislerdir. Bu matrisler arasında uygulanan konvolüsyon işlemi geriye yayılım algoritmasında kullanılmamaktadır.

HYSA için geliştirilen öğrenme algoritmasında öncelikle yukarıdaki değişiklikler yapılmıştır. Aktivasyon fonksiyonu sürekli olmamasından dolayı değiştirilmemiş bunun yerine bölgesel türev ifadesine karşılık gelen yeni bir fonksiyon üzerinde durulmuştur.

HYSA’nın çıkış fonksiyonu şu şekilde ifade edilir:

$$y_{i,j}(n) = \frac{1}{2} (|x_{i,j}(n)+1| - |x_{i,j}(n)-1|) \quad (6.2)$$

Bu ifadenin açık yazılımı,

$$y(n) = \begin{cases} 1 & n \geq 1 \\ -1 & n \leq -1 \\ n & -1 < n < 1 \end{cases} \quad (6.3)$$

bağıntısı ile verilebilir.

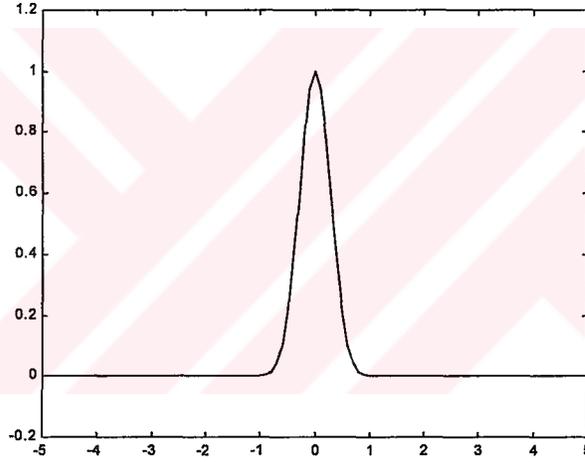
Bu fonksiyonun ayırık bölgeler için türev ifadesi ise,

$$y'(n) = \begin{cases} 0 & n \leq -1 \text{ ve } n \geq 1 \\ 1 & -1 < n < 1 \end{cases} \quad (6.4)$$

eşitlikleri ile gösterilir. $y'(n)$ eşitliklerinin yerine kullanmak amacı ile uygun fonksiyon seçiminin yapılması gerekmektedir. Bu amaçla Bölüm-3'de anlatılan dalgacık ailesinden yararlanılması düşünülmüştür. Yapılan araştırma sonucunda uygun 'a' ve 'b' değerlerinin seçimi ile Meksika Şapkası (Mexican Hat) olarak adlandırılan dalgacığın türev fonksiyonu yerine kullanılabileceği görülmüştür (Şekil 6.2). Bu fonksiyonun eşitliği,

$$\psi = (1 - a \cdot t^2) e^{-bt^2} \quad (6.5)$$

ile ifade edilir.



Şekil 6.2 a = 0.1 ve b = 2 için Meksika Şapkası dalgacığı

Türev fonksiyonu probleminin çözümlenmesinden sonra geriye yayılım algoritmasının HYSA için düzenlenmesindeki diğer kısıtlamaların giderilmesi gerekmektedir. Bu algoritmanın HYSA için ortalama karesel hata ifadesi şu şekildedir:

$$E(\omega) = \frac{1}{2} \sum_N \sum_{i,j} (y_{i,j}^k(\infty) - t_{i,j}^k)^2 \quad (6.6)$$

$y_{i,j}(\infty)$, HYSA'nın k. durum çıkışıdır. Burada kararlı durum ağı çıkışlarının $[-1,1]$ değerlerini ulaşması olarak tanımlanır. Ağı çıkışları bu değerleri aldığı anda öğrenme sonlandırılır. Yaklaşık ortalama karesel hata için adımsal düşüm (steepest descent)

algoritmasının güncellenmiş ağırlıklarının eşitliği şu şekildedir:

$$\omega(k+1) = \omega(k) - \alpha \cdot \frac{\partial E(\omega)}{\partial \omega(k)} \quad (6.7)$$

Bu eşitlikteki kısmi türevin bulunmasında zincir kuralı kullanılarak:

$$\frac{\partial E(\omega)}{\partial \omega(k)} = (y_{i,j}^k(\infty) - t_{i,j}) \frac{\partial y_{i,j}^k(\infty)}{\partial \omega(k)} \quad (6.8)$$

$$\frac{\partial y_{i,j}^k(\infty)}{\partial \omega(k)} = \frac{\partial F(x_{i,j}^k(\infty))}{\partial x_{i,j}^k(\infty)} \frac{\partial x_{i,j}^k(\infty)}{\partial \omega(k)} \quad (6.9)$$

bağıntıları bulunur. (6.9) eşitliğindeki F fonksiyonunun türev ifadesi Meksika Şapkası fonksiyonuna karşılık düşmektedir.

$$\frac{\partial F(x_{i,j})}{\partial x_{i,j}} = (1 - 0.1x_{i,j}^2) e^{-2x_{i,j}^2} \quad (6.10)$$

$$\frac{\partial x_{i,j}^k(\infty)}{\partial \omega(k)} = Y_{i,j}^k \quad (6.11)$$

Bu eşitliklerin kullanımı ile (6.7) ifadesi şu şekilde yazılabilir:

$$\omega(k+1) = \omega(k) - \alpha Y_{i,j}^k \cdot (1 - 0.1x_{i,j}^k) e^{-2x_{i,j}^k} \cdot (y_{i,j}^k(\infty) - t_{i,j}^k) \quad (6.12)$$

k : İterasyon sayısı

$\omega(k+1)$: Yeni ağırlık değeri

$\omega(k)$: Bir önceki ağırlık değeri

α : Öğrenme oranı

$Y_{i,j}^k$: Giriş matrisi

$x_{i,j}^k$: Başlangıç matrisi

$y_{i,j}^k(\infty)$: k. İterasyon sonucunda HYSA'nın kararlı durum çıkışı

$t_{i,j}^k$: Hedeflenen çıkış matrisi

Yapılan düzenlemeler sonucunda algoritma çalışırken HYSA'nın ileri yönlü işlem akışında ağırlıkların İBA yapısına benzetiminden dolayı oluşabilecek kayıplardan etkilenmemesi için HYSA'nın kendi yapısının kullanılması daha uygundur. Böylelikle ileri yayılım esnasında HYSA kendi içinde kararlı duruma ulaşarak $y_{i,j}^k(\infty)$ çıkışını üretir ve bu yeni çıkış değerleri yeni ağırlıkların ayarlanmasında kullanılır .

Yeni ağırlıkların ayarlanmasında (6.12) eşitliğinde kullanılan $x_{i,j}^k$ giriş değerinin iteratif olarak değişmesi, sonuca yakınsamamaya neden olduğundan dolayı ileri yönlü ağırlarda kullanılan sabit giriş benzetmesi yapılmıştır. Bu amaçla giriş değeri olarak ilk giriş $x_{i,j}^2$ değeri her bir ağırlık ayarlanması işleminde sabit olarak alınmıştır. Bu düzenlemeler sonucunda yeni ağırlıkların ayarlanmasını veren (6.12) eşitliği aşağıdaki şekilde yazılır,

$$\omega(k+1) = \omega(k) - \alpha Y_{i,j}^k \cdot (1 - 0.1 x_{i,j}^2) e^{-2x_{i,j}^2} \cdot (y_{i,j}^k(\infty) - t_{i,j}^k) \quad (6.13)$$

Hücrel yapay sinir ağının matematiksel ifadesi (6.14) eşitliği ile ifade edilir.

$$x_{i,j}(n+1) = \sum A y_{i,j}(n) + \sum B u_{i,j} + I \quad (6.14)$$

Bu eşitlikteki A ve B şablon matrisleri 3x3 boyutunda seçilmiştir (Eşitlik (6.15) ve (6.16)). Daha yüksek boyutlu şablon matrisleri seçilebilir, fakat bu işlem yükünü artıracığından dolayı tercih edilmemektedir. Bu iki matrisin toplam eleman sayısı 18'dir. Skalar olarak kullanılan I eşik değeri eklenince toplam eleman sayısı 19 olmaktadır. İşlem süresini azaltmak için simetri özelliği kabulü yapılarak (6.17) ve (6.18) eşitlikleri yazılabilir. Böylelikle (6.19) eşitliği ile ifade edilen ω ağırlık matrisi 11 elemana indirgenmiş olur (Güzeliş,1994).

$$A = \begin{bmatrix} a_1 & a_2 & a_3 \\ a_4 & a_5 & a_6 \\ a_7 & a_8 & a_9 \end{bmatrix} \quad (6.15)$$

$$B = \begin{bmatrix} b_1 & b_2 & b_3 \\ b_4 & b_5 & b_6 \\ b_7 & b_8 & b_9 \end{bmatrix} \quad (6.16)$$

$$a_1 = a_9, a_2 = a_8, a_3 = a_7, a_4 = a_6 \quad (6.17)$$

$$b_1 = b_9, b_2 = b_8, b_3 = b_7, b_4 = b_6 \quad (6.18)$$

$$\omega = [a_1 a_2 a_3 a_4 a_5 b_1 b_2 b_3 b_4 b_5 I]^T \quad (6.19)$$

HYSA'na giriş verileri 16x16, 64x64, 128x128, 256x256 gibi büyük boyutlarda görüntüler olabilmektedir. A ve B matrislerine göre büyük boyutlu olan bu görüntü matrisleri HYSA'nın 'y' çıkış ve 'u' durum matrislerini oluşturmaktadır. A ve B şablon matrisleri ile 'y' ve 'u' matrislerinin konvolüsyonlarının geriye yayılım algoritması için düzenlenmesi sonucu çıkış ve durum matrisleri şu şekilde yazılır:

$$Y_{i,j}^k = [Y_{i-1,j-1}^k + Y_{i+1,j+1}^k \quad Y_{i-1,j}^k + Y_{i+1,j}^k \quad Y_{i-1,j+1}^k + Y_{i+1,j-1}^k \quad Y_{i,j-1}^k + Y_{i,j+1}^k \quad Y_{i,j}^k]^T \quad (6.20)$$

$$U_{i,j}^k = [U_{i-1,j-1}^k + U_{i+1,j+1}^k \quad U_{i-1,j}^k + U_{i+1,j}^k \quad U_{i-1,j+1}^k + U_{i+1,j-1}^k \quad U_{i,j-1}^k + U_{i,j+1}^k \quad U_{i,j}^k]^T \quad (6.21)$$

Bu eşitlikler kullanılarak konvolüsyon işlemi yerine matris çarpımları yapılabilir. Bu düzenlemeler sonucunda hücresel yapay sinir ağının eğitimi için iki algoritmanın ardışıl çalışması esasına dayanan Dalgacık Öğrenme Algoritması oluşturulmuştur. Bu algortimalardan birincisi, HYSA'nın kararlı durum çıkışını üreten ileri yönlü yayılım algoritmasıdır. İkincisi, hatayı minimize etmeye yönelik geriye yayılım algoritmasıdır.

Kararlı durum çıkışlarını üreten ileri yönlü algoritmanın akış diyagramı Şekil 6.3'de görülmektedir. Bu akış diyagramının adımları şu şekilde çalışır:

1. Adım :

$n=1$ için giriş $x_{i,j}(n)$ değerinin aktivasyon fonksiyonundan geçirilerek $y_{i,j}(n)$ değerinin bulunması.

2. Adım :

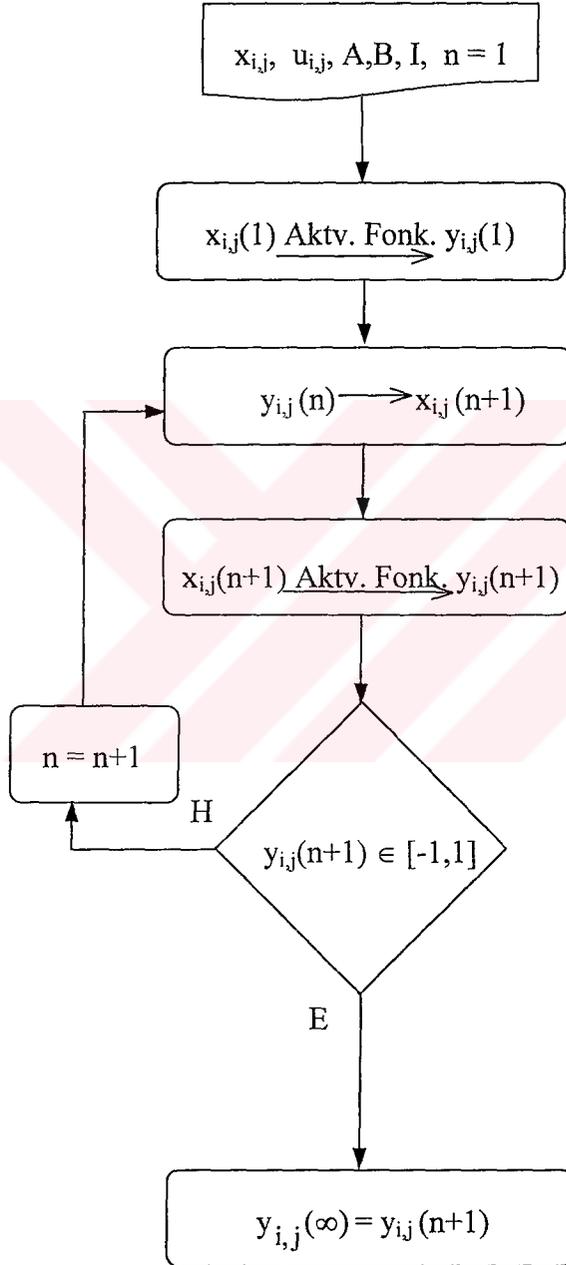
$y_{i,j}(n)$ değerinin (6.14) eşitliğinde yerine konularak $x_{i,j}(n+1)$ değerinin bulunması

3. Adım :

$x_{i,j}(n+1)$ değerinin aktivasyon fonksiyonundan geçirilerek $y_{i,j}(n+1)$ değerinin bulunması.

4. Adım :

$y_{i,j}(n+1)$ çıkış değeri $[-1, 1]$ kümesinin elemanı ise $y_{i,j}(\infty)$ değerine ata ve algoritmayı sonuçlandır. Değil ise n 'yi 1 artır ve 2. Adıma git.



Şekil 6.3 Kararlı durum çıkışlarını üreten ileri yönlü algoritmanın akış diyagramı

Bu adımlar sonucunda HYSA ortalama 1-100 iterasyon sonucunda kararlı durum çıkışını

üretmektedir. Bu çıkışlar ile istenilen çıkışlar karşılaştırılarak hatanın sıfır olup olmamasına bakılır. Hata sıfır değil ise ağ geriye doğru işlem adımlarını gerçekleştirerek yeni A,B ve I değerlerini oluşturur. Bu ikinci algoritmanın akış diyagramı Şekil 6.4'de görülmektedir. Bu akış diyagramının adımları şu şekilde çalışır:

1. Adım :

Dalgacık fonksiyonunda değişken olarak $x_{i,j}^2$ giriş değerini al.

2. Adım :

Yeni giriş değerlerini ve $u_{i,j}$ değerlerini $Y_{i,j} = [y_{ij} \ u_{ij} \ I]$ giriş vektörü olarak yaz.

3. Adım :

A,B şablonlarını ve I eşik değerini düzenle, ω ağırlık vektörünü oluştur (Eşitlik 6.19).

4. Adım :

HYSA'yı başlangıç ω vektörü için çalıştır ve $y_{i,j}(\infty)$ kararlı durum çıkış matrisini bul.

5. Adım :

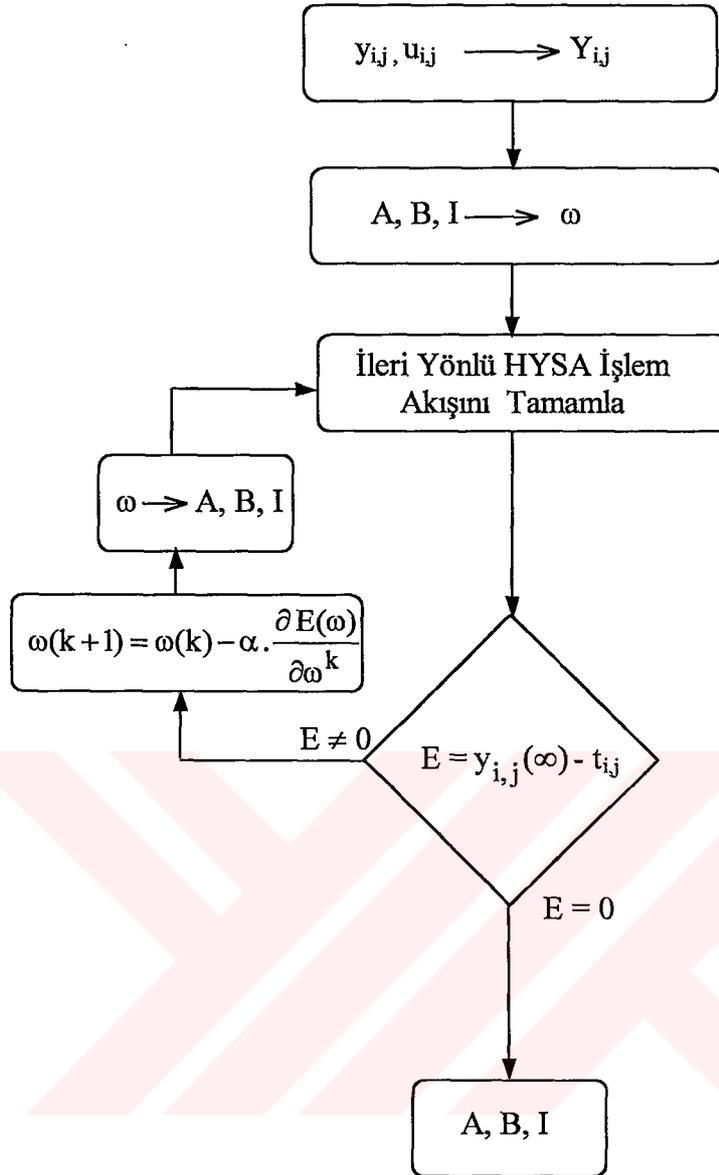
Kararlı durum çıkışı $y_{i,j}(\infty)$ ile hedeflenen çıkış $t_{i,j}$ 'yi karşılaştır. Fark sıfır ise algoritmayı sonlandır değil ise, adımsal düşüm algoritmasını çalıştır.

6. Adım :

Ayarlanan yeni ω ağırlık vektöründen A,B şablon matrislerini ve I eşik değerini oluştur.

7. Adım :

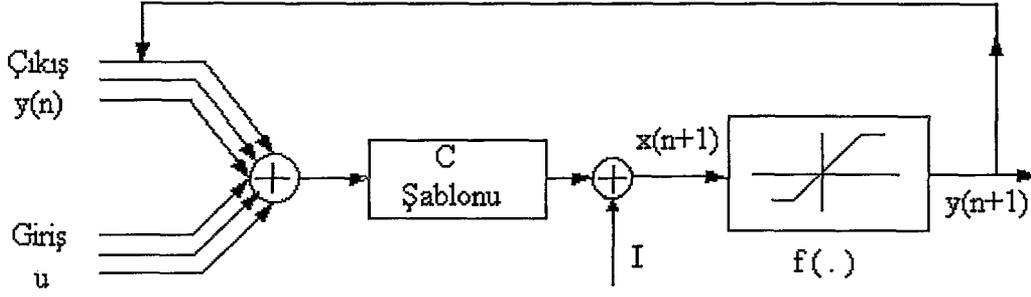
Yeni şablon ve eşik değeri için HYSA'yı çalıştır, kararlı durum çıkışı $y_{i,j}(\infty)$ 'ı bul ve 5. adıma git.



Şekil 6.4 Hatayı minimize etmeye yönelik geriye yayılım akış diyagramı

6.1.1 Dalgacık Hücresel Yapay Sinir Ağı Mimarisi

Hücresel yapay sinir ağının eğitiminde, dalgacık öğrenme algoritması (DÖA) kullanılarak A, B, I değerlerinin ayarlanması gerçekleştirilmektedir. İşlem süresini kısaltmaya yönelik olarak A ve B matrislerinin eşit olması kabulü yapılarak bu iki şablon yerine kullanılabilir tek bir C şablonunun bulunması amaçlanmıştır. Bu kabul ile yapılan eğitim sonucunda iki şablon yerine tek bir şablonun kullanılabilirliği bir ağ yapısı elde edilmiştir. Bu daha küçük mimariye sahip ağ, *Dalgacık Hücresel Yapay Sinir Ağı (DHYS)* olarak adlandırılmıştır (Şekil 6.5).



Şekil 6.5 DHYSA'nın mimarisi

DHYSA'nın tek şablondan oluşan matematiksel ifadesi şu şekildedir:

$$x_{i,j}(n+1) = \sum C (y_{i,j}(n) + u_{i,j}) + I \quad (6.22)$$

$$y_{i,j}(n) = \frac{1}{2} (|x_{i,j}(n)+1| - |x_{i,j}(n)-1|) \quad (6.23)$$

Bu yeni mimari eğitim ve test aşamalarında iki konvolüsyon yerine bir konvolüsyon işlemi gerektirdiğinden ve ağırlık vektörünün boyutu 11'den 6'ya indirildiğinden dolayı işlem sayısı azalmıştır. Böylelikle işlem hızı artmış ve tümleşik devre uygulamalarında kolaylık sağlanmıştır.

7. GÖRÜNTÜ İŞLEME UYGULAMALARI

Geliştirilen yeni öğrenme algoritması ve hücrel yapay sinir ağı mimarisinin farklı görüntüler üzerinde performans analizi yapılmıştır. DHYSA'nın kenar belirleme uygulamalarındaki başarımı ve hızı incelenmiştir. DÖA kullanılarak jeofizik maden görüntülerinin ayrıştırılması ve arkeolojik görüntülerin iyileştirilmesi uygulamaları gerçekleştirilmiştir. Bulunan sonuçlar klasik yöntemlerle karşılaştırılarak verilmiştir.

DÖA ve DHYSA uygulamaları Pentium II-300 işlemcili ve 32 MB hafızaya sahip bir PC ortamında MATLAB programlama dili kullanılarak gerçekleştirilmiştir. Öncelikle eğitim programı hazırlanarak çalıştırılmış ve daha sonrasında bulunan ağırlık değerleri dosyaya kaydedilmiştir. Bu ağırlık değerleri test programında kullanılmak üzere dosyadan çağrılarak test aşaması gerçekleştirilmiştir. Eğitim programı kodları Ek 2'de ve test programı kodları Ek 3'de verilmiştir.

7.1 Kenar Belirleme

Görüntü işlemenin bir çok alanında karakteristik özelliklerin çıkarılmasına ihtiyaç duyulmaktadır. Kenar bilgileri, frekans ve renk bilgisi bu karakteristik özelliklere örnek olarak verilebilir. Bu özelliklerden en önemlisi diyebileceğimiz kenar belirleme yöntemi, kodlama, sıkıştırma, tanıma, bölütleme gibi bir çok görüntü işleme uygulamalarında kullanılmaktadır. Kenar bilgileri lokal yoğunluk değişimi bilgilerinin ortaya çıkarılması temeline dayanmaktadır. Bu işlemler yapılırken türev ifadelerinden yararlanır.

Tek boyutlu bir fonksiyonda birinci türevin ekstremum noktaları lokal değişmeye karşılık düşmektedir. Görüntü yoğunlukları, sürekli fonksiyonların serisi olarak düşünüldüğünde bu değişim gradyent ile ölçülebilir. Gradyent, birinci türevin iki boyutlu eşitliği olarak gösterilir.

Vektörel gösterim ifadesi ise:

$$G[f(x,y)] = \begin{bmatrix} G_x \\ G_y \end{bmatrix} = \begin{bmatrix} \frac{\partial f}{\partial x} \\ \frac{\partial f}{\partial y} \end{bmatrix} \quad (7.1)$$

bağıntısı ile verilir.

Gradyent iki önemli özellik içermektedir: (1) $G [f(x,y)]$ vektörü $f (x,y)$ fonksiyonunun artım yönünü gösterir (2) gradyentin genliğini veren,

$$G[f(x,y)] = \sqrt{G_x^2 + G_y^2}$$

eşitliği G yönündeki her birim uzunluktaki $f(x,y)$ 'nin maksimum artım oranını gösterir.

Gradyent genlik eşitliği yaklaşık olarak,

$$G[f(x,y)] \approx |G_x| + |G_y| \quad (7.3)$$

veya

$$G[f(x,y)] \approx \max(|G_x|, |G_y|) \quad (7.4)$$

bağıntıları ile ifade edilebilirler.

Vektör analizinde gradyent yönü ifadesi,

$$\alpha(x,y) = \tan^{-1} \left(\frac{G_y}{G_x} \right) \quad (7.5)$$

bağıntısı ile tanımlanır.

Kenar belirlemede birinci türevin ekstrema noktalarına karşılık gelen bir diğer ifade ikinci türevdeki sıfır geçiş noktalarıdır. $f(x,y)$ fonksiyonunun ikinci türev ifadesine karşılık olarak Laplasyen eşitliği kullanılır;

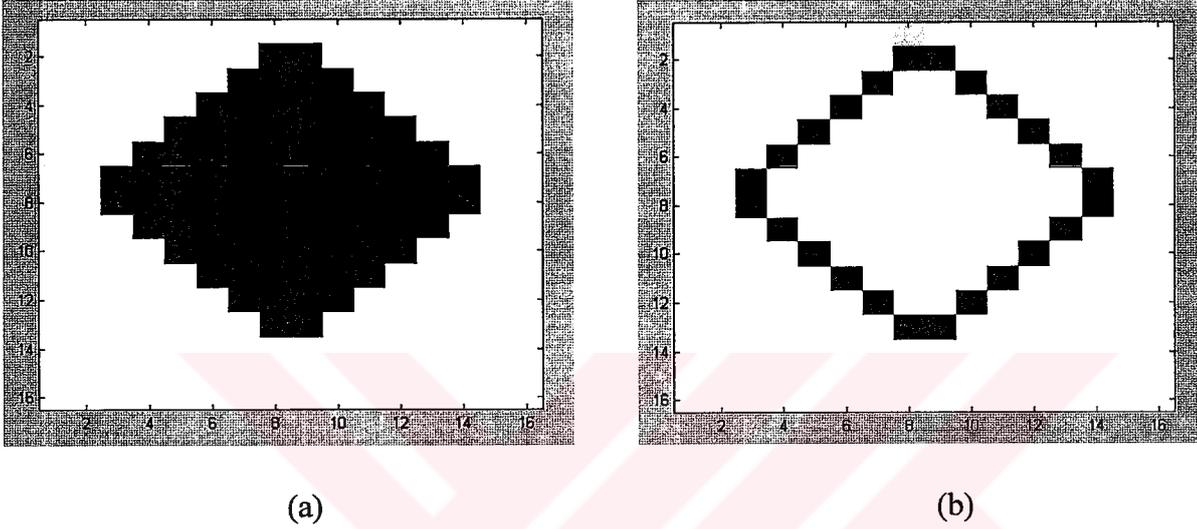
$$\nabla^2 f = \frac{\partial^2 f}{\partial x^2} + \frac{\partial^2 f}{\partial y^2} \quad (7.6)$$

Kenar belirleme yöntemleri bu temel bağıntılara göre dizayn edilmiş şablonlar kullanılmaktadır. Sobel, Roberts ve Prewitt gradyent bağıntılarını kullanan yöntemlerdir. Canny gradyent bağıntılarını ve Gauss filtreleme yöntemini kullanan bir kenar belirleme metodudur. Laplasyen yöntemi ise ikinci türev bağıntılarına göre dizayn edilmiş şablonlardan oluşmaktadır. Bu şablonlar kullanıma göre 3x3, 4x4, 9x9 boyutlarında olabilmektedir.

Bu klasik yöntemlerin yanı sıra farklı yaklaşım metodları da geliştirilmiş ve geliştirilmektedir. Bulanık mantık, yapay sinir ağları bu yeni yöntemlere örnek olarak verilebilirler. Bu çalışmada ise kenar belirleme yöntemi olarak dalgacık hücreli yapay sinir ağının kullanılabileceği ortaya konmuştur. Yapılan uygulamalar ile klasik yöntemlerin sonuçları karşılaştırılmalı olarak incelenmiştir.

7.1.1 DHYSA'nın Eğitim Aşaması

DHYSA'nın görüntü kenar belirleme uygulamalarında kullanılabilmesi için eğitim aşamasında 16x16 boyutlu $[-1,1]$ piksel değerli görüntülerin kullanılması yeterli olmaktadır. Bu amaçla Şekil 7.1'de görülen baklava dilimi görüntüsü giriş ve bu görüntünün kenarlarını gösteren görüntü hedef olarak seçilmiştir.



Şekil 7.1 a) Eğitim amaçlı 16x16'lık giriş görüntüsü, b) Eğitim aşamasındaki hedef görüntü

C ve I'nın başlangıç değerleri şu şekilde seçilmiştir,

$$C_{\text{kenar}} = \begin{bmatrix} -1 & -1 & -1 \\ -1 & -4 & -1 \\ -1 & -1 & -1 \end{bmatrix} \quad I = -1$$

Durum matrisi 'u', giriş matrisi 'x'e eşit seçilmiş ve öğrenme hızını belirleyen öğrenme oranı $\alpha=0.001$ olarak belirlenmiştir. Bu değerler kullanılarak DÖA ile yapılan eğitim sonucunda 125 iterasyon ile sonuca ulaşıldığı görülmüştür. Eğitim sonucunda bulunan şablon ve eşik değerleri şu şekildedir:

$$C_{\text{kenar}} = \begin{bmatrix} -0.3194 & -0.5709 & -0.3194 \\ -0.5798 & 3.6338 & -0.5798 \\ -0.3194 & -0.5709 & -0.3194 \end{bmatrix} \quad I = -1.5874$$

7.1.2 DHYSA'nın Test Aşaması

DHYSA'nın test aşamasında üç farklı görüntü sınıfı üzerinde çalışılmıştır. Bu sınıflar:

- Sentetik görüntüler,
- Kamera ile alınmış görüntüler,
- Tıbbi görüntülerdir.

Bu görüntülerin DHYSA kenar belirleme sonuçlarının karşılaştırılması amacı ile Canny, Sobel, ve Laplasyen kenar belirleme yöntemleri kullanılmıştır. Klasik yöntemlerin kullanımı için yazılmış Matlab programı Ek 4'de verilmiştir.

7.1.2.1 Sentetik Görüntüler

Sentetik görüntüler bilgisayar ortamında Paint Brush programı kullanılarak elde edilmiş 236 x 236 boyutlu siyah beyaz çizimlerdir. Harf ve rakam görüntülerinin DHYSA kenar belirleme sonuçları Şekil 7.2'de görülmektedir. Diğer sentetik görüntüler için klasik kenar belirleme yöntemleri Canny, Sobel, Laplasyen yöntemleri ile DHYSA'nın karşılaştırmalı sonuçları Şekil 7.3'de verilmiştir.

7.1.2.2 Kamera ile Alınan Görüntüler

Kamera ile alınmış 256 x 256 boyutlarında gerçek ortama ait pirinç ve damla görüntüleri ile kenar belirleme uygulaması gerçekleştirilmiştir. Bu görüntülerin DHYSA ,Canny, Sobel ve Laplasyen yöntemleri kullanılarak elde edilmiş kenar görüntüleri Şekil 7.4 ve Şekil 7.5'de görülmektedir.

7.1.2.3 Tıbbi Görüntüler

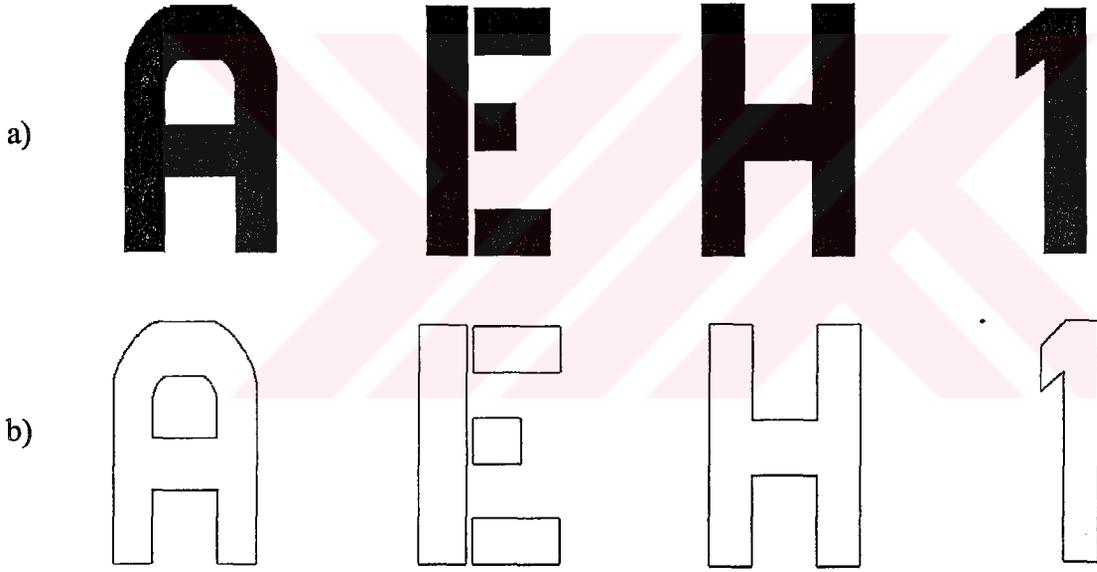
Görüntü bölütleme, tıbbi görüntülerin işlenmesinde bir çok kullanım alanı olan önemli bir yöntemdir. Anjiogramda damar çeperlerinin tespiti, yaralardaki sertleşmelerin ölçülmesi, cerrahi gösterimler, cerrahi planlamalar, tümör tespiti, tümör hacminin ölçülmesi ve terapiye verdiği cevabın belirlenmesi, fonksiyonel haritalama, kan hücrelerinin sınıflanması, beyin gelişiminin izlenmesi gibi birçok alanda uygulamaları vardır. Tıbbi görüntüleme ise bölütleme, özellik çıkartımı, görüntü ölçümleri ve görüntünün gösteriminde önemlidir. Kemik, kas ve kan damarlarındaki kanser, doku zedelenmesi gibi patolojik bölgeleri ayırmada

kullanılır.

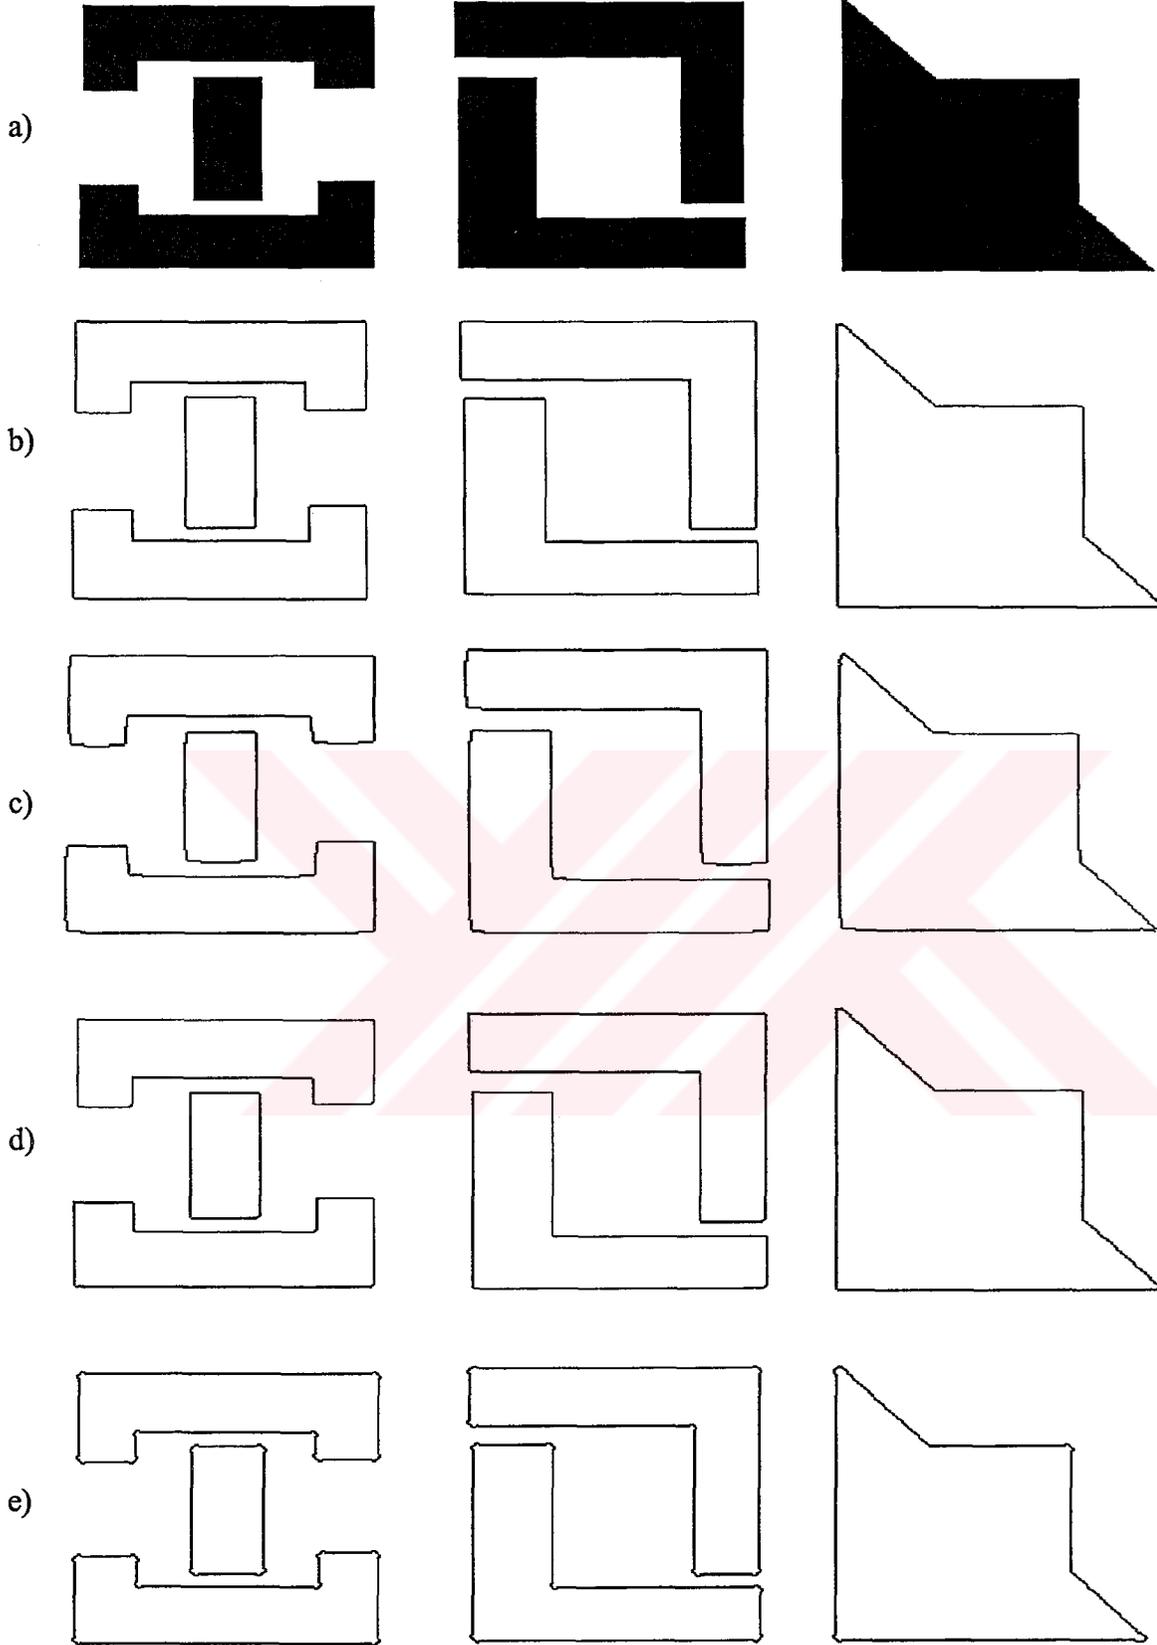
Tedavi aşamasına örnek olarak radyasyon terapisi verilebilir. Radyasyon terapisinde amaç tümöre yüksek dozda radyasyon vererek tümörü yok etmektir. Bu işlem esnasında tümörün etrafındaki sağlıklı organların radyasyon almaması gerekmektedir. Bunun için tümör şeklinin, boyutlarının, çevresinin tam olarak belirlenmesi ve radyasyon ışınlarının konfigürasyonun bu sonuçlara göre optimum olarak ayarlanması istenir. Bu aşamada tümörün kenarlarının belirlenmesinden yararlanır.

Bu bölümde tümörlü bir beyne ait MR (Manyetik Rezonans) görüntüsünün kenarlarının belirlenmesi DHYSA kullanılarak gerçekleştirilmiştir. DHYSA sonuçları, Canny, Sobel ve

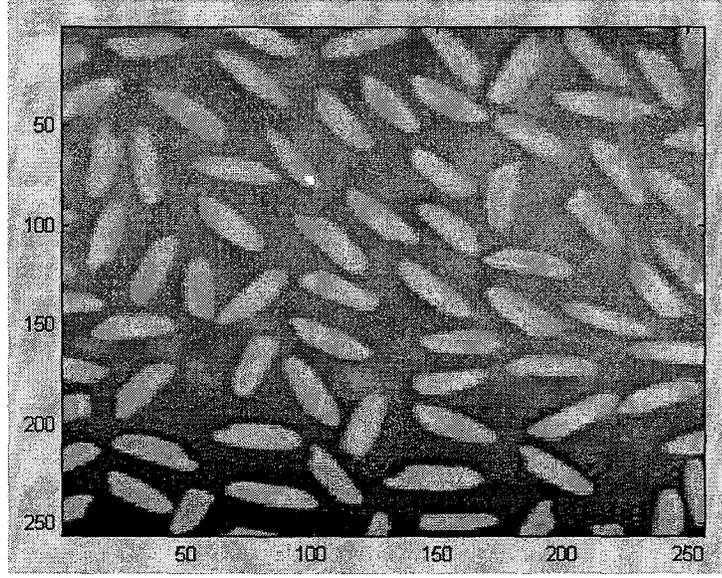
laplasyen yöntemlerinin sonuçları ile birlikte Şekil 7.6'da görülmektedir.



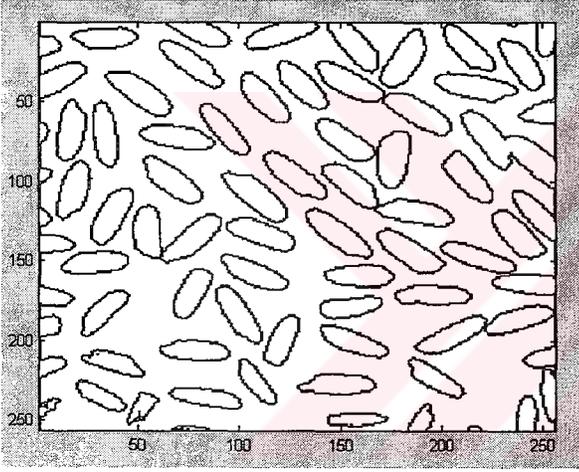
Şekil 7.2 a) Giriş görüntüleri, b) DHYSA sonuçları



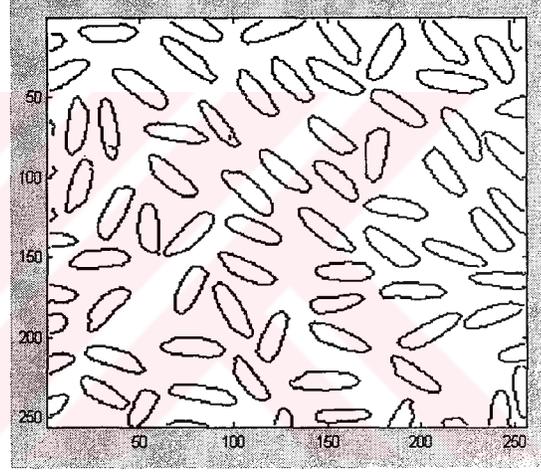
Şekil 7.3 a) Giriş görüntüleri, b) DHYSA sonuçları, c) Canny sonuçları, d) Sobel sonuçları
e) Laplasyen sonuçları



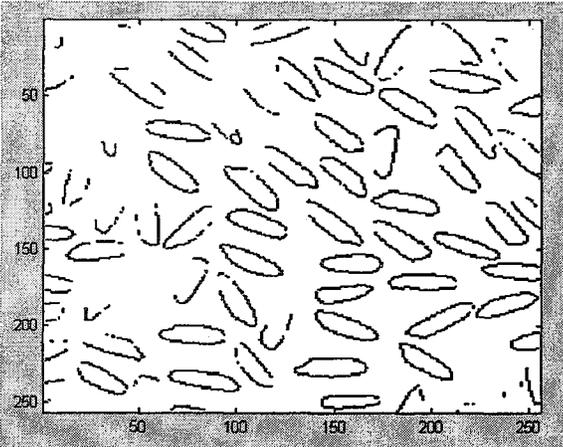
a)



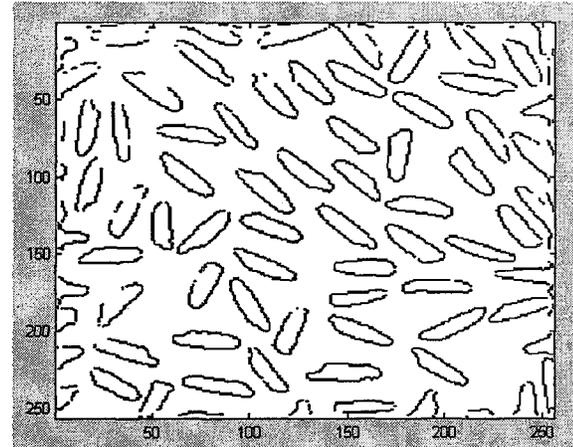
b)



c)

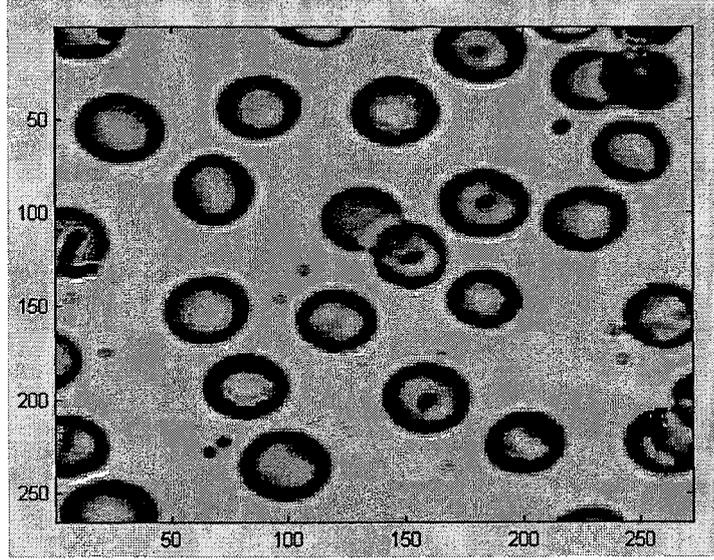


d)

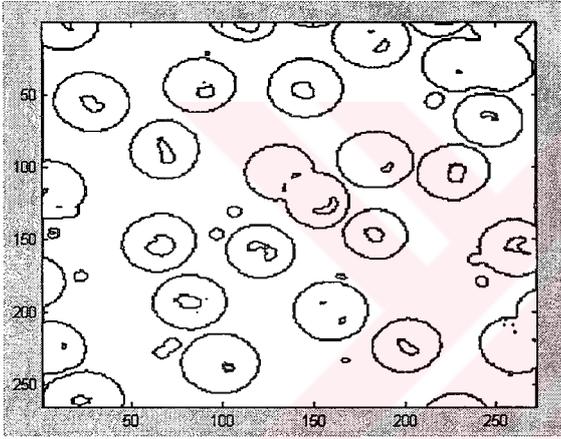


e)

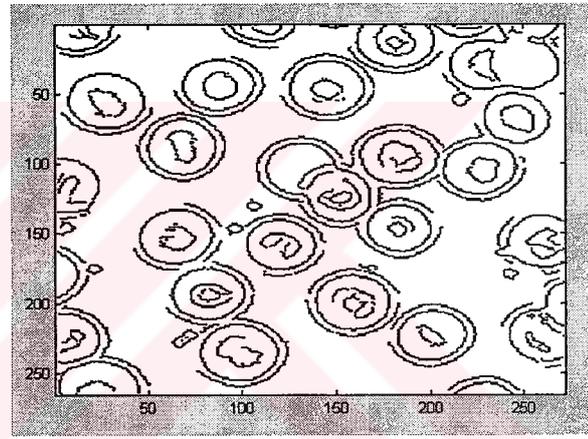
Şekil 7.4 a) 256 x 256 Boyutlu pirinç görüntüsü, b) DHYSA sonuçları, c) Canny sonuçları, d) Sobel sonuçları e) Laplasyen sonuçları



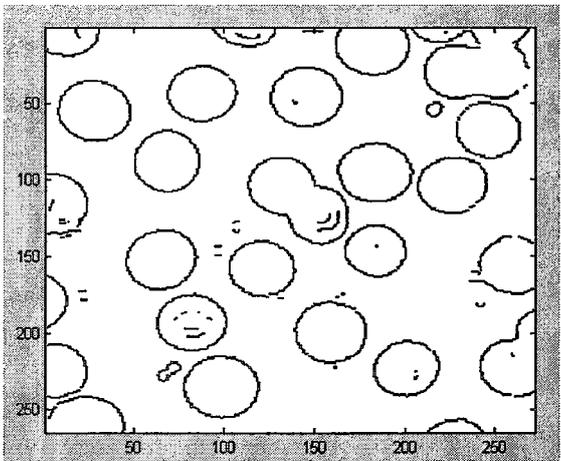
a)



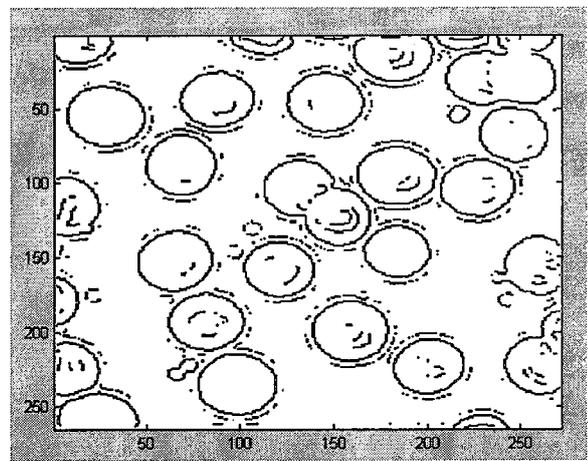
b)



c)

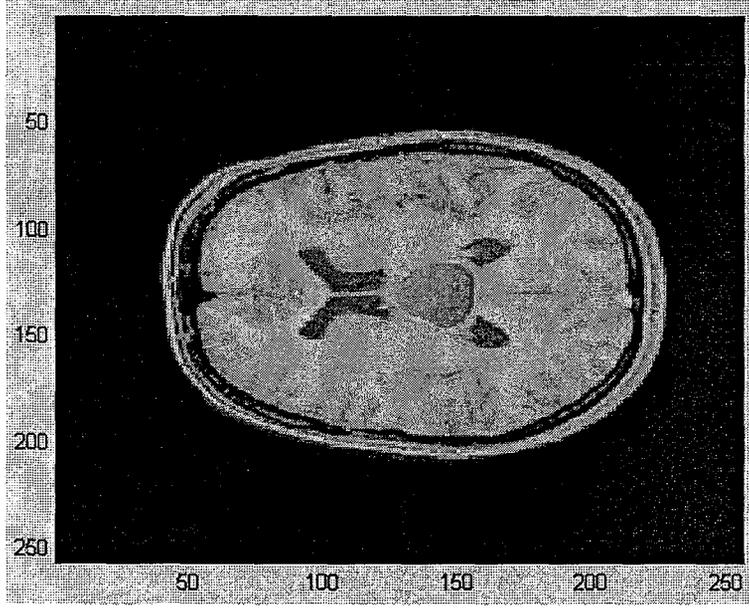


d)

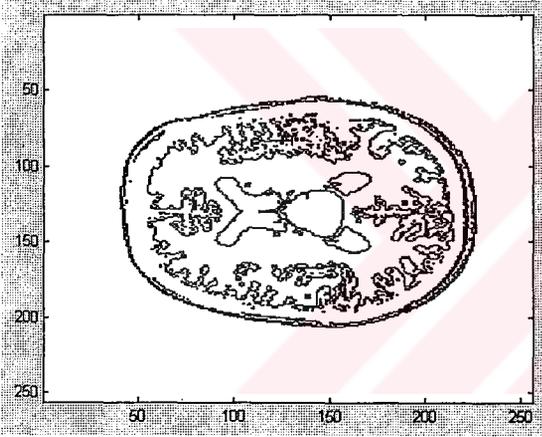


e)

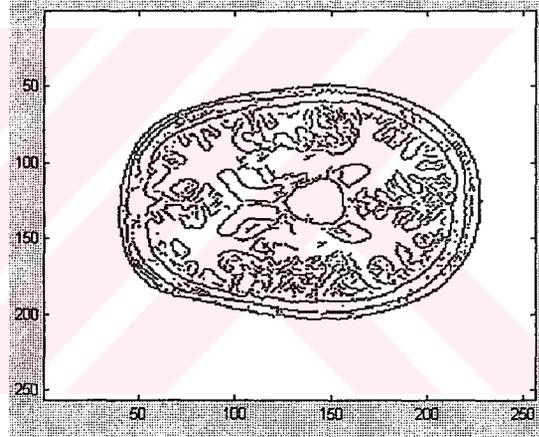
Şekil 7.5 a) 256 x 256 Boyutlu damla görüntüsü, b) DHYSA sonuçları, c) Canny sonuçları, d) Sobel sonuçları e) Laplasyen sonuçları



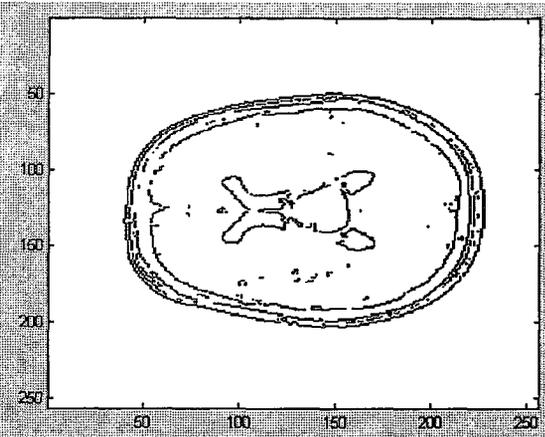
a)



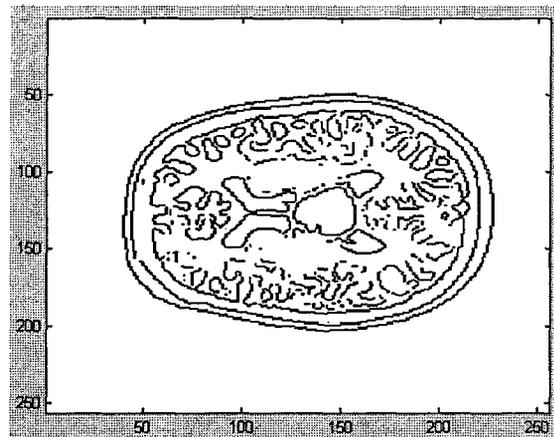
b)



c)



d)



e)

Şekil 7.6 a) 256 x 256 boyutlu MR görüntüsü, b) DHYSA sonuçları, c) Canny sonuçları, d) Sobel sonuçları e) Laplasyen sonuçları

7.2 Jeofizik Verilerinin Analizi

Uygulamalı jeofiziğin konusu yer kabuğunun üst kısmında bulunan, boyutları sınırlı ve derinliği az olan yeraltı yapılarını ve özel durumlarını incelemektir. Yer altındaki antiklinalleri (tepelik), senklinalleri (çukurluk), fayları, maden yatakları ve sedimanların (çökelim) altındaki temel kayacın engebelerini aramak bu tür çalışmalara girer. Bu aramaların bir çoğunun maden, petrol, su aramak ve zemin etütleri gibi ekonomik bir amacı vardır. Her ne kadar uygulamalı jeofizik sığ derinlikteki yapı ve özel durumları incelerse de kullanılan arama yöntemlerinden bazıları, yerkürenin çok daha derin kısımlarını incelemek için de geçerli olabilmektedir. Jeofizikte kullanılan temel arama yöntemleri şu şekilde sıralanabilir:

- Gravite (yerçekimi) yöntemi
- Manyetik yöntemler
- Elektrik ve Elektromanyetik yöntemler
- Sismik yöntemler

Bu yöntemlerin kullanılması ile elde edilen verilerin analizi sonucu, yer altı ile ilgili bilgiler elde edilir. Potansiyel kaynaklı (Gravite ve Manyetik) yöntemlerden elde edilen ölçümlerde derinden gelen ve yüzeye yakın yapıların etkisi mevcuttur. Bu etkiyi ortadan kaldırmak için çeşitli türev metodları, filtre yöntemleri, analitik uzanımlar, yuvarlatma yöntemleri bu alanda kullanılan klasik analiz metodlarıdır. Son zamanlarda dalgacık yöntemi (Albora 2000), rastgele yapay sinir ağları (Danacı 2001) gibi yeni yöntemlerin kullanımı üzerinde çalışmalar yapılmaktadır. Bu yöntemler ile yeraltındaki değişik yapıların yeryüzünde oluşturdukları toplam gravite etkilerinin ayrıştırılarak her bir yapının etkisinin ayrı ayrı ortaya çıkarılması sağlanmaktadır. Hücresel yapay sinir ağlarının da filtre özelliği bu alanda başarılı kullanımına olanak tanımaktadır. HYSAN'ın kullanıldığı daha önceki çalışmalarda (Özmen 2001) A,B,I değerleri deneme-yanılma yöntemi kullanılarak ayarlanmış ve çok başarılı sonuçlar elde edilmiştir. Bu çalışmada ise öğrenmeli HYSAN kullanılarak otomatik olarak ağırlık katsayıları ayarlanmış ve gerçek veriler üzerinde uygulamalar yapılmıştır.

7.2.1 Gravite Yöntemi

Yeraltının homojen olmaması ve değişik yoğunluklu kayalardan oluşması nedeni ile yerçekimi ivmesi 'g'de küçük değişimler meydana gelir. Bu değişimlerin, yeryüzünde özel

aletlerle ölçülmesi ve bu ölçü değerlerinin yorumlanması gravite yönteminin temelini meydana getirir. Bu yöntem kullanılarak, yeraltında değişik yoğunluklardan oluşan yerçekimi ivmesi 'g'nin küçük değişimleri ölçülerek yeraltında aranan cisim veya jeolojik yapı hakkında bilgi edinilir.

Bir maden yatağı ile etrafındaki kayacın yoğunlukları arasında fark yoksa, böyle bir maden yatağı gravite yöntemi ile bulunamaz. Ayrıca, yeraltının hep yatay tabakalardan oluşması halinde de bu durum gravite yöntemi ile saptanamaz.

Gravite yöntemi, yerkürenin şeklinin, yapısının araştırılması ve sondaj amaçlarına yöneliktir. Sondaj amaçlı araştırmalarda özellikle petrol aramalarında, krom, demir vb. gibi fazla yoğunluk sunan metallerin belirlenmesinde, tuz domlarının saptanmasında ve üstü örtülü, içi düşük yoğunluk sunan malzeme ile dolu tünel türü yapıların araştırılmasında, yer altı mağaralarının bulunmasında yaygın olarak kullanılır.

Gravite yönteminin Türkiye'deki uygulamasına ilk olarak Maden Tetkik Arama Enstitüsünde başlanmıştır. Çoğunlukla petrol aramalarında uygulanmıştır. Günümüzde de petrol aramalarında ön etüd olarak gravite yöntemi uygulanmaktadır.

Gravite yönteminin maden aramalarında daha çok yoğunluk farkı büyük olan madenlere uygulanması daha başarılı sonuçlar verir. Ayrıca mikro gravite aletlerinin son yıllarda teknolojinin ilerlemesi ile yaygın kullanım alanları bulmaktadır. Özellikle küçük etki yaratan cisimlerin ortaya çıkartılması için mikro graviteden yararlanılmaktadır. Daha çok arkeolojik sahalarda, yer altında aranacak olan yapı veya nesnelere için mikro gravite önemli ölçüde çözüm sağlar.

7.2.1.1 Gravitenin Temel İlkesi

Gravitenin temel ilkesini Newton kanunu oluşturur. Buna göre, m ve m' gibi iki kütlelerin birbiri üzerine uyguladığı F çekim kuvveti, kütlelerin çarpımlarıyla doğru, aralarındaki uzaklığın karesiyle ters orantılıdır.

$$F = G \frac{m \cdot m'}{r^2} \quad (7.7)$$

Burada G gravitasyon sabiti olup, $G=6.67 \cdot 10^{-8} \text{ cm}^3/\text{gr.sn}^2$ dir. $F = m \cdot a$ denklemi (7.7) eşitliğinde yerine konacak olursa ivme,

$$a = G \frac{m}{r^2} \quad (7.8)$$

eşitliği elde edilir. İvme, m kütlesinin kendisinden r uzaklıktaki birim kütleyle uyguladığı çekim kuvveti olarak tanımlanır.

7.2.1.2 Potansiyel Teori

Bir m birim kütlesinin r uzaklığında bulunan bir P noktasındaki gravite potansiyeli $W_p = G \frac{m}{r}$ ve bir V hacmini kapsayan M kütlesi için $W_p = G \iiint \frac{dm}{r}$ dir. W_p potansiyeli, kütlenin bulunmadığı yerlerde Laplace denklemini, kütlenin bulunduğu yerlerde ise Poisson denklemini gerçekleştirir. Bu şekilde tanımlanan potansiyelden, M kütlesinin P noktasına uyguladığı kuvvetin ivmesi,

$$g = -\text{grad}W = -\left(\vec{i} \frac{\partial W}{\partial x} + \vec{j} \frac{\partial W}{\partial y} + \vec{k} \frac{\partial W}{\partial z} \right) \quad (7.9a)$$

formülüyle bulunur. Buradaki g 'ye yerçekimi ivmesi (gravite) denir. Gravite vektörünün koordinat eksenleri boyunca olan bileşenleri ise

$$g_x = -\frac{\partial W}{\partial x} = G \iiint \frac{(x-x')dm}{r^3} \quad (7.9b)$$

$$g_y = -\frac{\partial W}{\partial y} = G \iiint \frac{(y-y')dm}{r^3} \quad (7.9c)$$

$$g_z = -\frac{\partial W}{\partial z} = G \iiint \frac{(z-z')dm}{r^3} \quad (7.9d)$$

olarak elde edilir. Burada $r^2 = (x-x')^2 + (y-y')^2 + (z-z')^2$ dir. İşte gravite yönteminin uygulamasında yalnız buradaki (g_z) ölçülür ve literatürde bu sadece (g) ile gösterilir. Başlangıç koordinatı olarak $x'=y'=z'=0$ alınırsa,

$$g = G \iiint \frac{z \cdot dm}{r^3} \quad (7.10)$$

olur. Burada, $r^2 = x^2 + y^2 + z^2$ dir.

Jeofizik uygulamalarında gravite birimi olarak (Galileo) kelimesinin ilk hecesi olan (gal)

kullanılır. 1 gal=1 cm/sn² dir. Gal pratikte kullanılan sayılara göre çok büyük bir birim olduğu için, pratikte bunun yerine (miligal) kullanılır ve kısaca (mgal) olarak gösterilir. 1 mgal=0.001 gal= 0.001 cm/sn² dir.

7.2.1.3 Model Çalışma Yöntemi

Çeşitli jeofizik yöntemlerle elde edilen ölçüm sonuçlarının normal yada ortalama değerlerden farklı olan ve belirli bir biçim gösteren değerlerinin bütününe anomali denir. Jeofizik yöntemleri uygulamadaki amaç anomali elde etmektir.

Gravite anomalilerinin değerlendirilmesinde ise anomaliyi meydana getiren yer altı cisminin geometrik modeli düşünülerek, bunun yeryüzünde meydana getireceği gravite alanı teorik olarak hesaplanır. Böylece elde edilen teorik eğrilerle arazi ölçümlerinden eğrilerin karşılaştırılması yoluyla yer altındaki cismin şekli hakkında fikir edinilebilir. Bugünkü bilgisayar tekniği sayesinde teorik hesaplamaların yapılması çok kolaylaşmış olup, model çalışmaları gravite anomalilerinin değerlendirilmesinde en çok kullanılan yöntemlerden biridir. Burada yapılan çalışmalarda kürenin yapısı üzerinde durulmuştur.

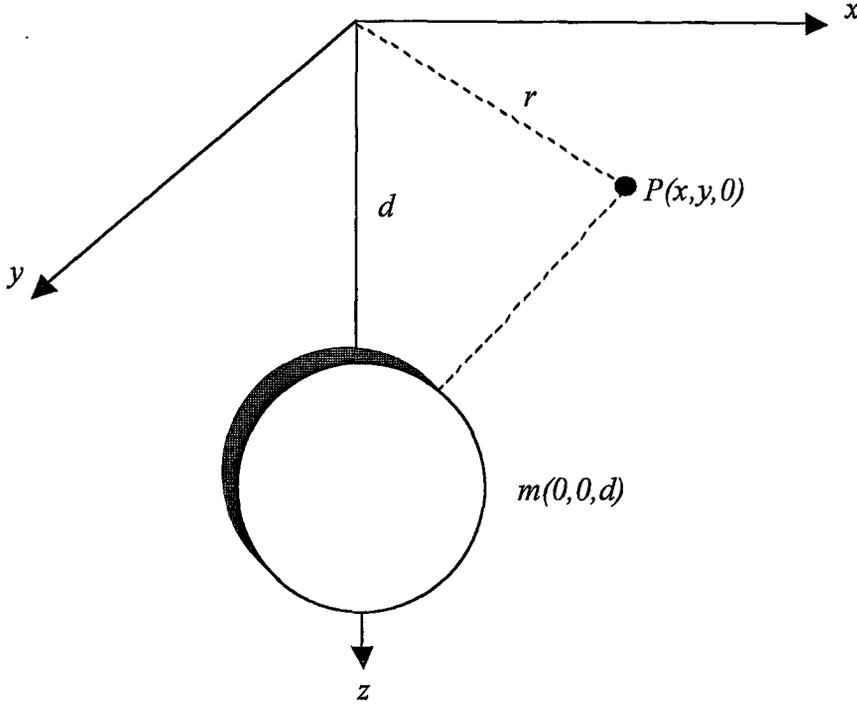
Kürenin gravite etkisi (Şekil 7.7) : Kütlesi m olan homojen bir kürenin dışında bulunan bir P noktasına uyguladığı çekim kuvveti, kürenin merkezinde bulunan ve kütlesi aynı olan nokta kütleinin P noktasına uyguladığı kuvvete eşit olur. P noktasının koordinatları (x,y,z) ve kürenin merkezi, koordinat başlangıcının altında d derinliğinde ise, P noktasındaki gravite,

$$g = \frac{-G.m.(z-d)}{[x^2 + y^2 + (z-d)^2]^{3/2}} \quad (7.11)$$

olur. Bu eşitlikte 'g' potansiyel alan etkisini, G gravitasyon sabitini göstermektedir. P noktası yeryüzü düzleminde ise (z=0 için)

$$g = \frac{G.m.d}{(r^2 + d^2)^{3/2}} \quad (7.12)$$

bulunur. Burada, $r^2 = x^2 + y^2$ dir.



Şekil 7.7 'P' Noktasının yeryüzü düzleminde gösterimi.

7.2.2 Manyetik Yöntem

Manyetik yöntemin amacı yer kabuğundaki manyetik özelliği bulunan yapıların araştırılmasıdır. Bilindiği gibi gravite yönteminde arzın o noktadaki bağıl veya mutlak gravitesi diğer bir değişle çekimin sadece düşey bileşeni ölçülür. Manyetik yöntemlerde ise birden fazla bileşen ölçülebilmektedir. Bu özellik gravite ile manyetik yöntemler arasındaki temel farklılıktır.

Manyetik yöntemde bir cismin anomali verebilmesi için yapının etrafındaki diğer yapılara göre farklı manyetik duyarlılık sunması gerekir. Manyetik duyarlılığı yüksek olan minerallere örnek olarak manyetit, pirotin, ilmenit, hematit sayılabilir. Manyetik yöntem ile bu mineraller, bu mineralleri içeren minerilizasyon zonları veya kayaçları aranır. Yöntem ayrıca petrol yapılarının aranmasında ve arkeolojik kalıntıların tesbitinde de kullanılır. Bazı tortul havzaların temel kayaçlarını oluşturan plütonik veya metamorfik kayaçların üst yüzeydeki engebeler de manyetik yöntemle saptanabilir. Çünkü metamorfik veya plütonik kayaçların duyarlıkları tortullara göre fazladır. Bu şekilde havzanın temel yapısının ortaya çıkartılmasında da kullanılır.

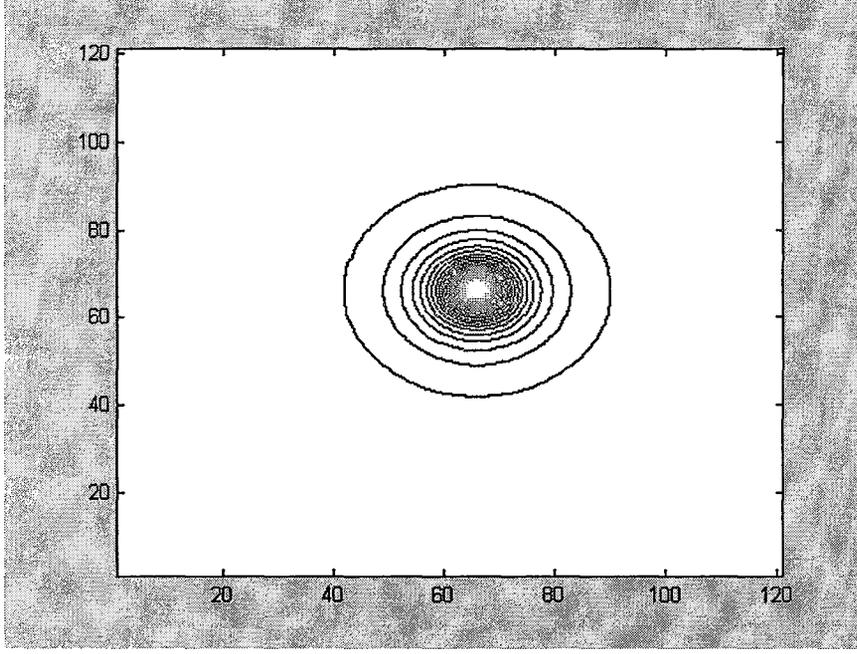
7.2.3 HYSA'nın Jeofizik Verilere Uygulanması

Gravite ve manyetik haritaların analizinde HYSA'nın kullanılabilmesi için öncelikle sentetik veriler ile eğitilmesi gerekmektedir. Yeraltındaki cisimlerin yeryüzünde meydana getirdikleri gravite çekim etkilerinin yapay olarak üretilebilmesi için belli ağırlık, yoğunluk ve hacime sahip küreler kullanılır. Bu küreler, yeryüzünde oluşturulan göreceli bir koordinat eksenine göre farklı derinliklere yerleştirilirler. Farklı özelliklerdeki bu her bir kürenin yeryüzünde oluşturdukları etkiler toplanarak gravite çekim etkisi elde edilir. Bunun için (7.11) eşitliğinden yararlanılır.

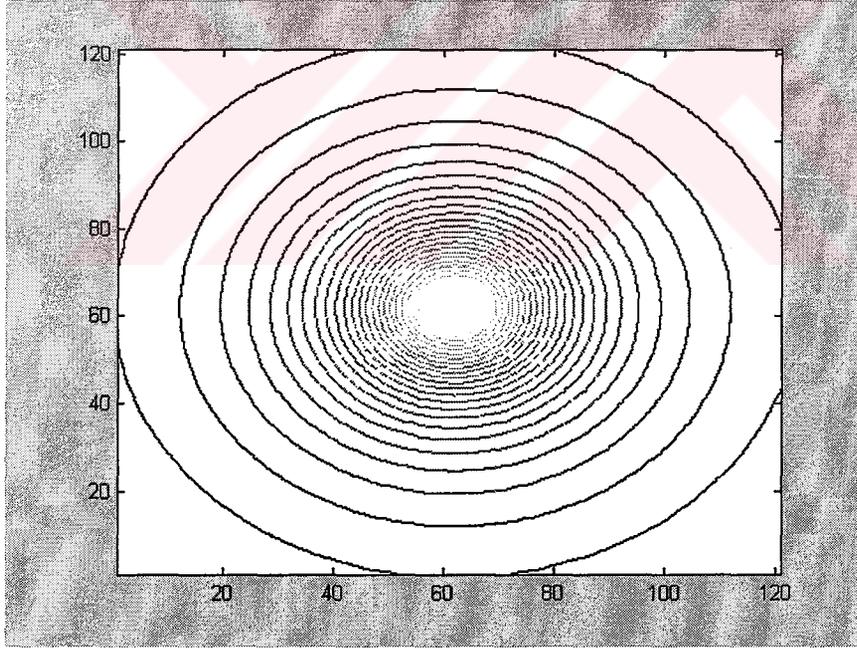
Eğitim için iki küre içeren bir gravite modeli oluşturulmuştur. Yer altına yerleştirilmiş bu kürelerin özellikleri Çizelge 7.1' de verilmiştir (Şekil7.8). Üretilen bu modelde kürelerin yeryüzünde oluşturdukları gravite etkileri hesaplanmıştır. Bu hesaplama sonucu elde edilen haritanın görüntüsü Şekil 7.9'da görülmektedir.

Çizelge 7.1 Sentetik bouguer anomali haritasının parametreleri.

<i>PARAMETRELER</i>	<i>KÜRE 1</i>	<i>KÜRE 2</i>
(x,y) koordinatlar	(5,5)	(1,1)
h (derinlik)	5	18
r (yarıçap)	2	1.4
ρ (yoğunluk)	1	1.2

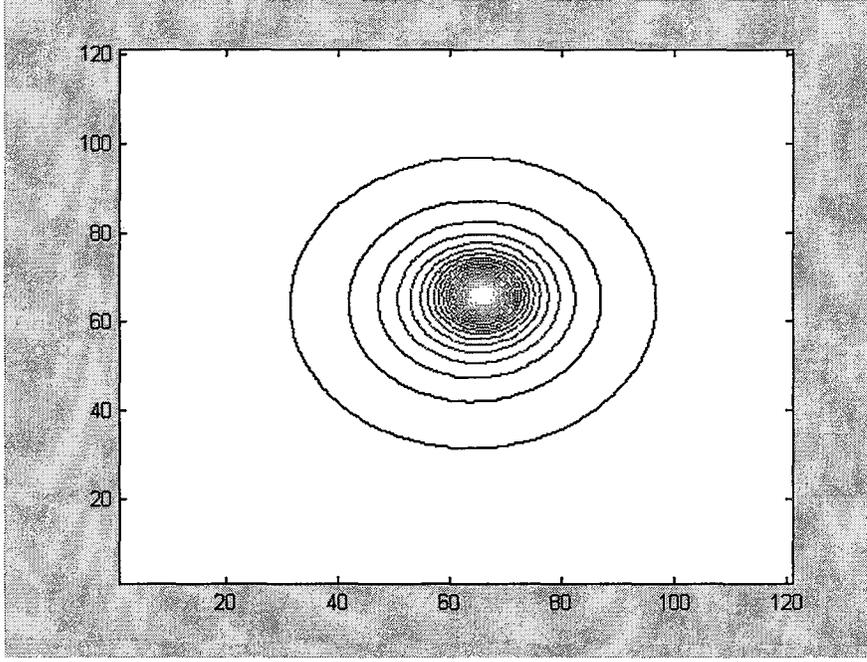


(a) Birinci kürenin gravite etkisi

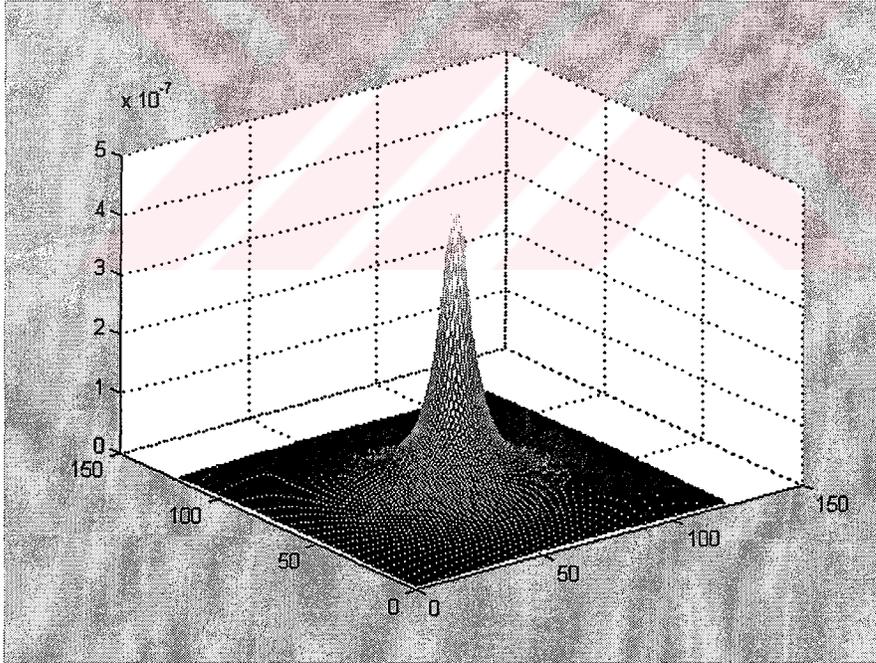


(b) İkinci kürenin gravite etkisi

Şekil 7.8 İki kürenin ayrı ayrı gravite etkileri



(a) Kürelerin toplam gravite etkisi



(b) Toplam gravite etkisinin üç boyutlu gösterimi

Şekil 7.9 İki kürenin toplam gravite etkileri

Bu sentetik gravite modeli ve DÖA kullanılarak HYSA'nın eğitimi yapılmıştır. Eğitim aşamasında giriş verileri 'u' yeryüzündeki toplam gravite etkisini gösteren görüntü olarak alınmış ve 'x' durum görüntüsü, giriş görüntüsü 'u' ile eşit seçilmiştir. A,B ve I'nun başlangıç değerleri şu şekilde alınmıştır:

$$A = \begin{bmatrix} 0 & 0 & 0 \\ 0 & 4 & 0 \\ 0 & 0 & 0 \end{bmatrix} \quad B = \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix} \quad I = -1$$

Hedef görüntü olarak yüzeye yakın birinci kürenin görüntüsü seçilmiştir (Şekil 7.8a). 28 iterasyon sonucunda eğitim sonuçlanmıştır. A, B, şablonları ve I eşiği aşağıdaki değerleri almıştır.

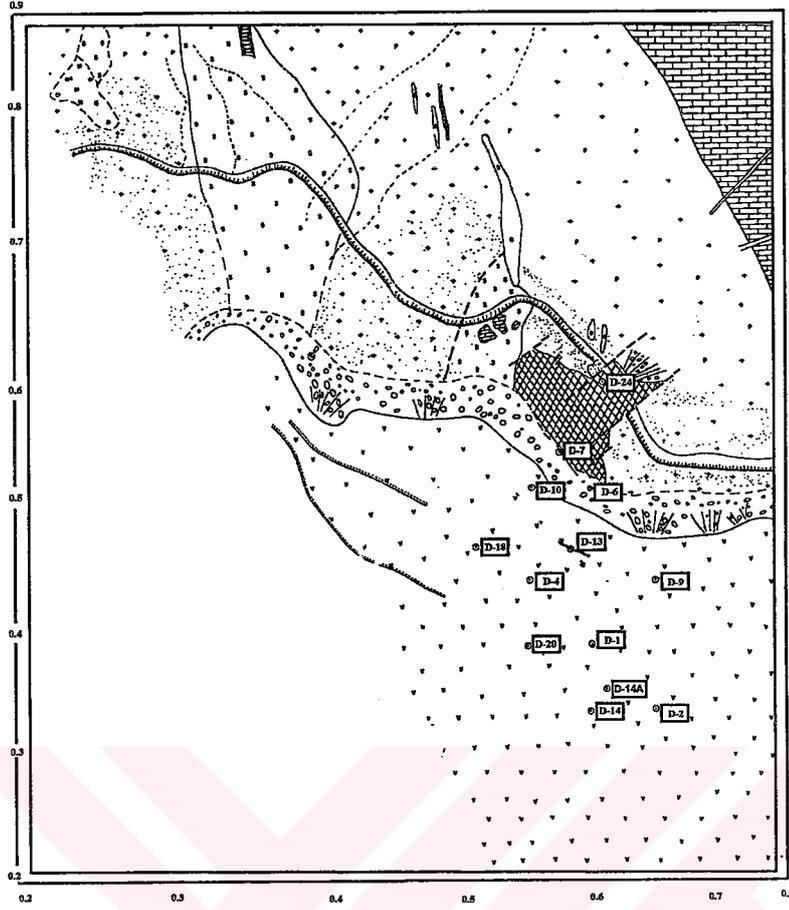
$$A = \begin{bmatrix} -0.1769 & -0.0884 & -0.1769 \\ -0.0884 & 3.9116 & -0.0884 \\ -0.1769 & -0.0884 & -0.1769 \end{bmatrix} \quad B = \begin{bmatrix} -0.1769 & -0.0884 & 0.0000 \\ -0.0884 & 0.0884 & -0.0884 \\ 0.0000 & -0.0884 & -0.1769 \end{bmatrix} \quad I = -0.9116$$

7.2.3.1 Dumluca Demir Madeni Sahasının Manyetik Anomali Haritası Analizi

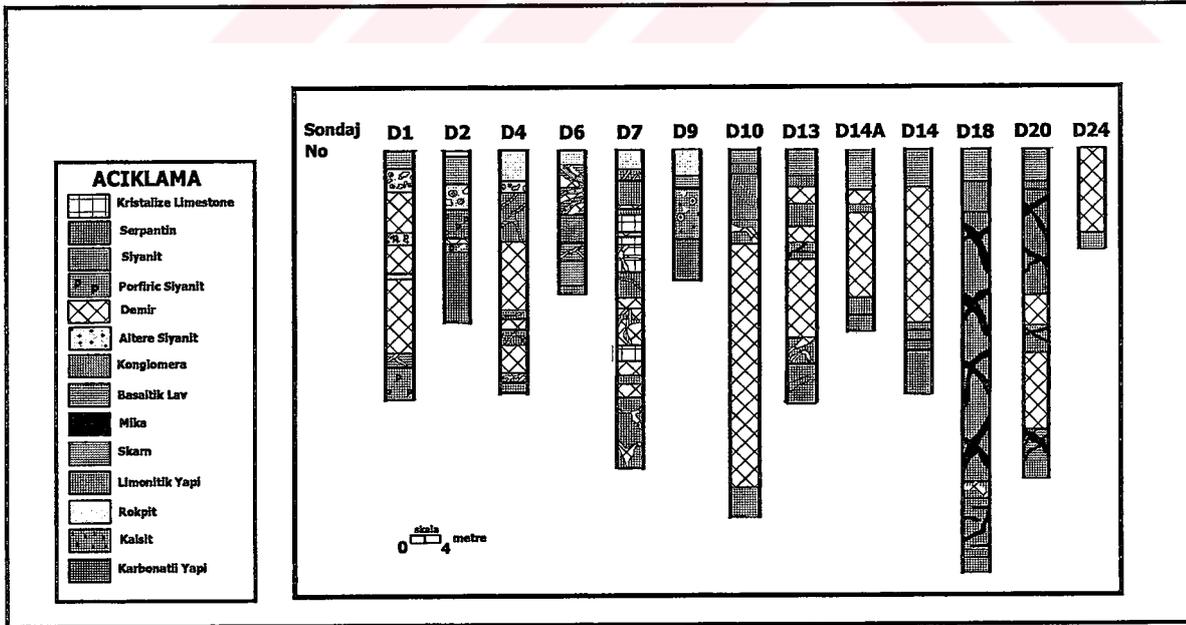
Sentetik gravite modeli kullanılarak eğitilmiş ve ağırlık katsayıları belirlenmiş HYSA kullanılarak gerçek jeofizik verileri üzerinde uygulama yapılmıştır. Bu amaçla Sivas ili Divriği ilçesinin kuzey batısında yer alan Dumluca demir yatağının manyetik anomali haritası kullanılmıştır. Bu bölgenin tercih edilmesinde önemli bir neden MTA'nın sondaj sonuçlarının bilinmesidir. Sonuçların doğruluğunun sınanmasında bu sondaj haritasından yararlanılmıştır (Şekil 7.10).

Yatak üzerinde ilk sondaj çalışması 1969 yılında yapılmıştır. Bu tarihte D-1, D-2, sondajları 1970 yılında D-4, D-6, D-9 sondajları MTA tarafından yapılmıştır. 1976 yılında MTA ve Türkiye Demir Çelik İşletmesi (TDCİ) birlikte sondaj programları uygulamışlardır. Bu süreçte D-10, D-13, D-14, D-14A, D-18, D-20, D-24 sondajları yapılmıştır. Bu sondajlardan D-18 ve D-9'da cevher kesilmediği görülmüştür (Şekil 7.11).

HYSA'nın iteratif filtreleme özelliği ile 8 iterasyon sonucunda maden yerlerinin belirlendiği görülmüştür. Elde edilen bu görüntü ile sondaj sonuçları karşılaştırıldığında birebir olarak

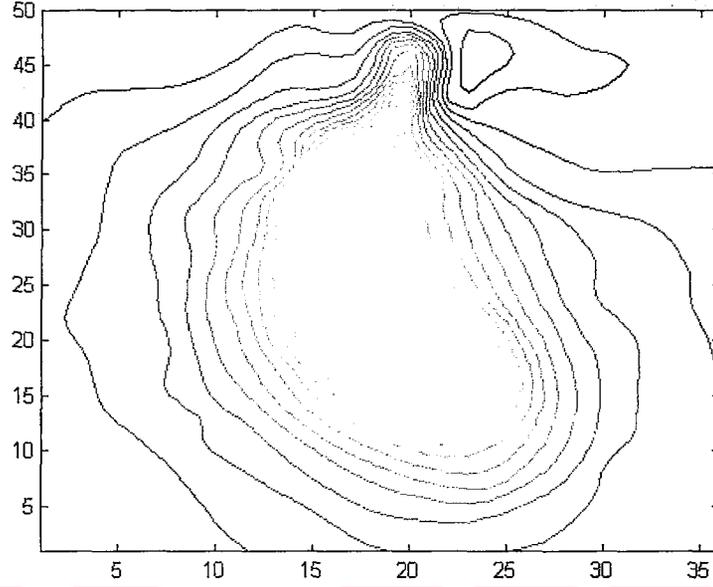


Şekil 7.10 Dumluca maden yatağının jeoloji haritası

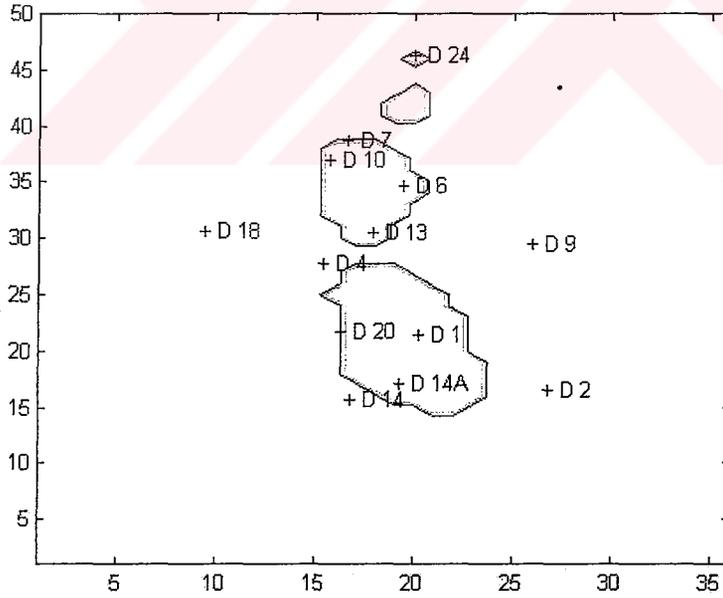


Şekil 7.11 Dumluca maden yatağının MTA sondaj sonuçları

örtüştüğü görülmektedir (Şekil 7.12). Aynı bölgenin klasik yöntemlerden Haalckın türev metodu ile analiz sonucu Şekil 7.13’de görülmektedir.

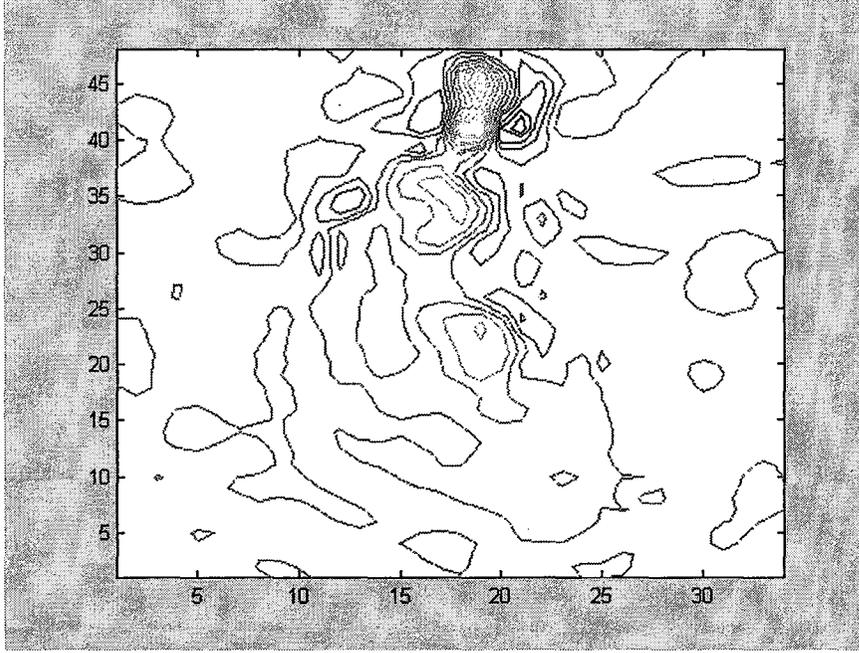


(a) Manyetik anomali haritası (MTA)



(b) HYSA sonucu elde edilen ayırım görüntüsü ve sondaj noktaları (MTA)

Şekil 7.12 Dumluca maden yatağının manyetik anomali haritası ve HYSA ayırım sonucu



Şekil 7.13 Dumlucayazı maden yatağı analizinde Haalck'ın türev metodu sonucu

7.3 Arkeolojik Görüntülerin Analizi

Gömülü durumdaki arkeolojik eserlerin görüntülenip, modelleyerek ortaya çıkartılmasında, jeofizik yöntemlerden son yıllarda oldukça yaygın olarak yararlanılmaktadır. Arkeoloğlardan alınan bilgiler doğrultusunda, aranacak olan arkeolojik yapılarda hangi jeofizik yöntemlerin kullanılması gerektiğine karar verilir. Yapılan çalışmalar sonucunda, arkeolojik eserin yeri ve konumu hakkında bilgi sahibi olunur. Böylelikle arkeolojik eserlerin sınırları belirlenerek, kazıya yön verilebilir ve arkeolojik esere herhangi bir hasar vermeksizin eserin bulunabileceği derinliğe kadar kazı yapılabilir.

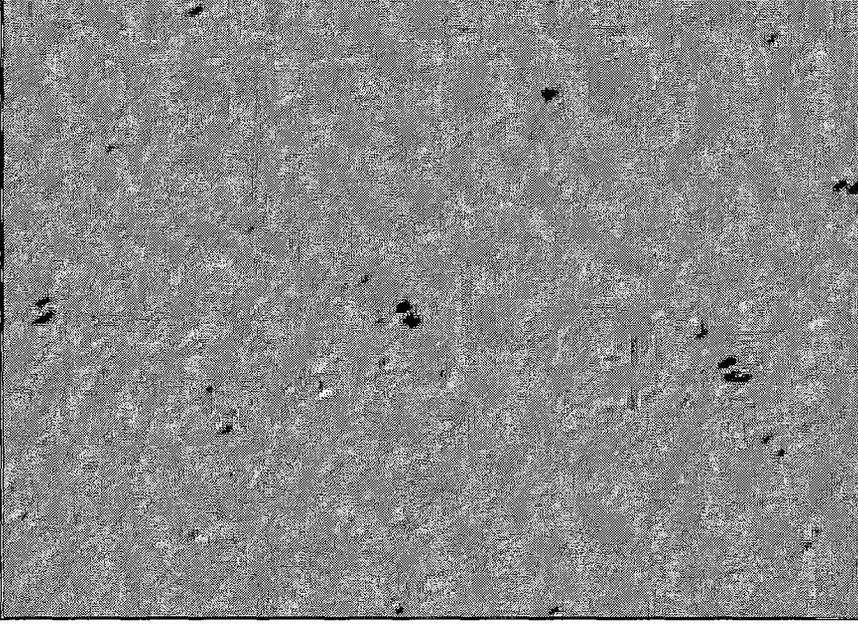
Önemli arkeolojik kalıntıların bulunduğu Anadolu'da Hitit uygarlığının yerleşmiş olması ve burada son bulması nedeniyle birçok bilim adamının dikkati bu topraklara çekilmiştir (Şekil 7.14). Hitit uygarlığının M.Ö. II bin yılının başlarında Anadolu'ya geldiği ve Kızılırmak Kavsi içindeki bölgeye yerleştikleri, arkeolojik kazılar sonucunda anlaşılmıştır.

1993 yılından itibaren bu bölgelerde devam eden jeofizik çalışmalar 1998 yılında Sivas-Kuşaklı'nın kuzeyinde yoğunlaşmaya başlamıştır. Şimdiye kadar şehir sur çemberinin içinde ve dışında ölçümler yapılmış ve Hitit şehri Sarissa'nın dördüncü şehir kapısının yeri

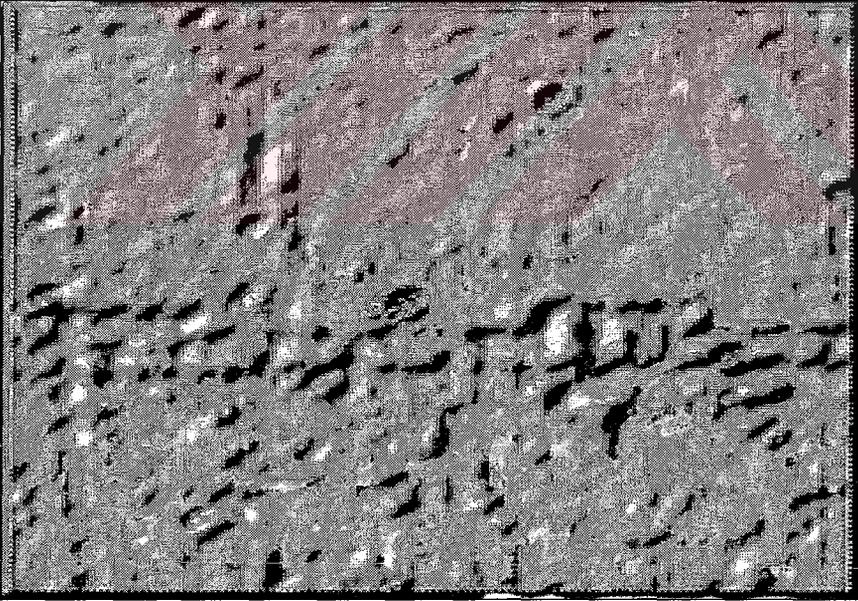
saptanmıştır. Bölgede yapılan çalışmalar sonucunda oluşturulan topografik harita Şekil 7.15’de görülmektedir. Bugüne kadar yapılan çalışmalar sonucunda ortaya çıkartılan binalar ve şehir duvarları topografik harita üzerinde gösterilmiştir. Arkeolojik analizler sonucunda, bu bölgedeki yapıların kuvvetli bir yangın felaketinin izlerini taşıdığı bilinmektedir. Bu kuvvetli yangın yapılarda kalıntı mıknatıslanmasına neden olduğundan dolayı manyetik yöntem sonucunda duvar yapıları kalıntı mıknatıslanma oluşturmakta ve manyetik anomaliler elde edilebilmektedir.

Bu anomaliler kullanılarak elde edilmiş duvar kalıntılarına ait görüntüler DÖA ve HYSA kullanılarak analiz edilmiştir. Şekil 7.16’da 555-600 boylamı ve 320-370 enleminde bulunan şehir duvarlarına ait arkeolojik görüntüler ve HYSA sonuçları görülmektedir. İlk görüntüde çok net olmayan duvar kalıntıları HYSA sonucunda biraz daha fazla belirginleştirilmiş ve sınırlar hakkında fikir sahibi olunmasında katkıda bulunmuştur.

Aynı bölgeye ait diğre bir arkeolojik görüntüde ise farklı yükseltilerdeki iki kalıntı görülmektedir (Şekil 7.17). Bu görüntünün HYSA analizi sonuçları ile zemin ve yükseltiler çok açık bir şekilde ayırt edilmiş ve yükseltilerin konumları hakkında bilgi sahibi olunmuştur (Şekil 7.18).

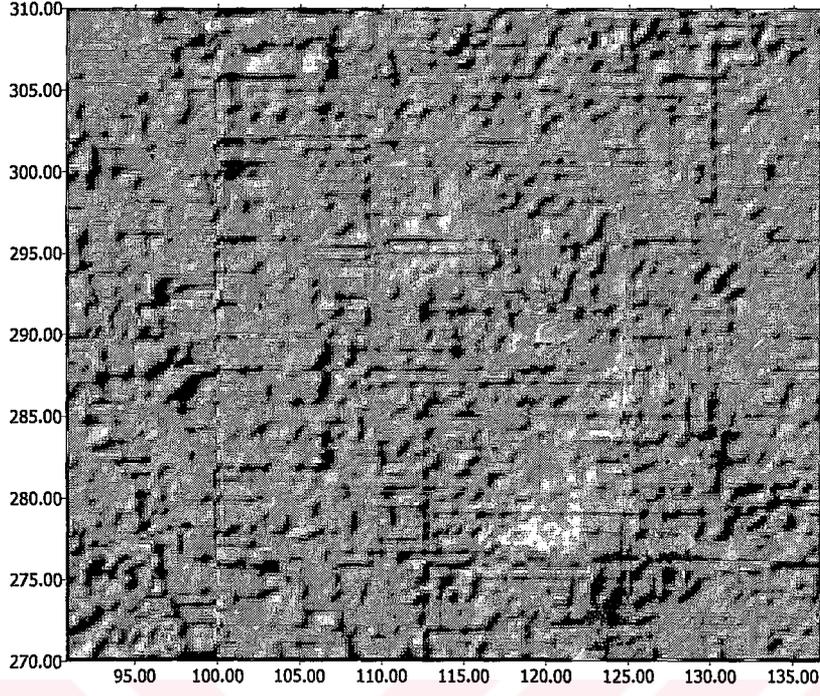


(a) Manyetik görüntüleme teknikleri kullanılarak elde edilmiş arkeolojik duvar görüntüsü

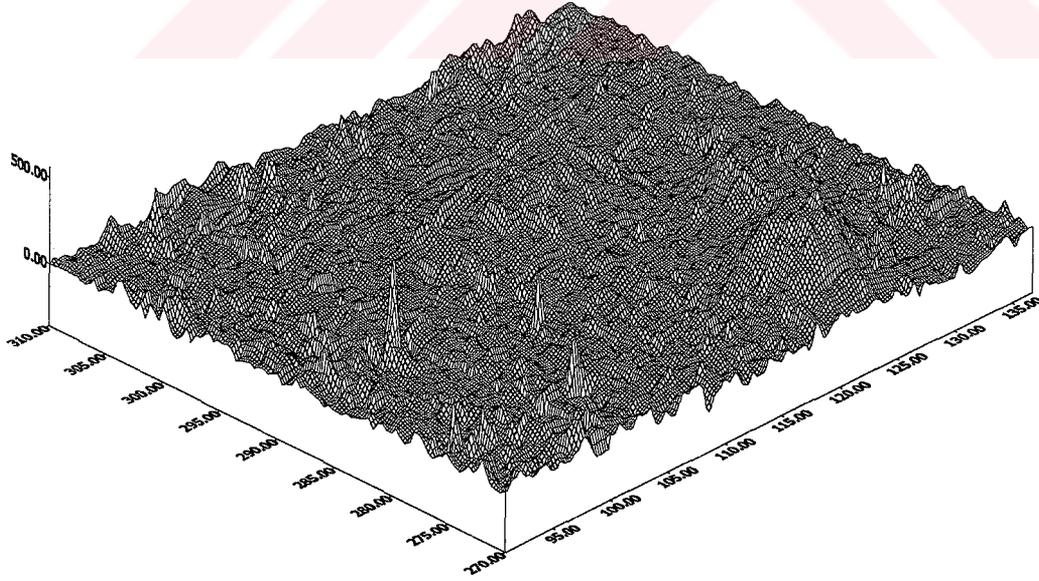


(b) HYSANIN sonucunda netleştirilmiş görüntü

Şekil 7.16 Hitit uygarlığına ait Kuşaklı Bölgesi Arkeolojik duvar görüntüsü ve HYSANIN analizi sonucu

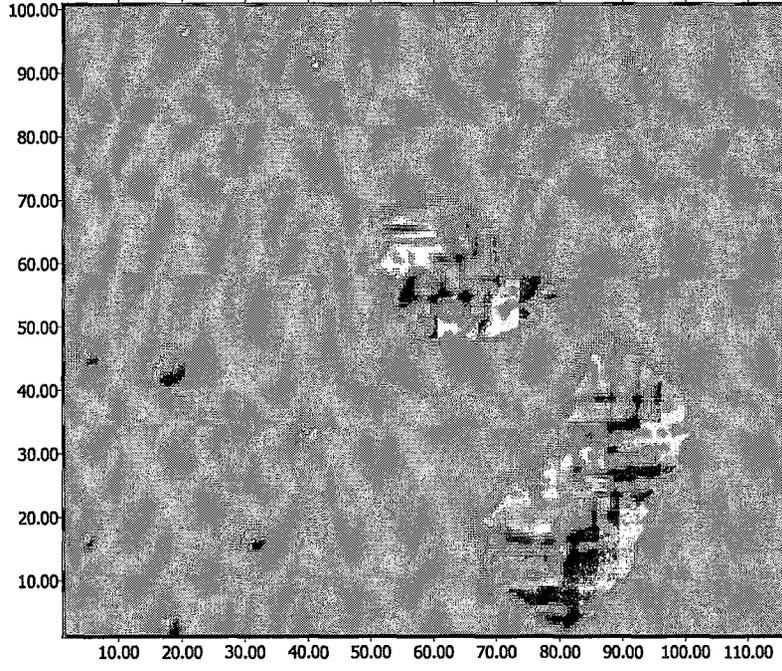


(a) Arkeolojik giriş görüntüsü

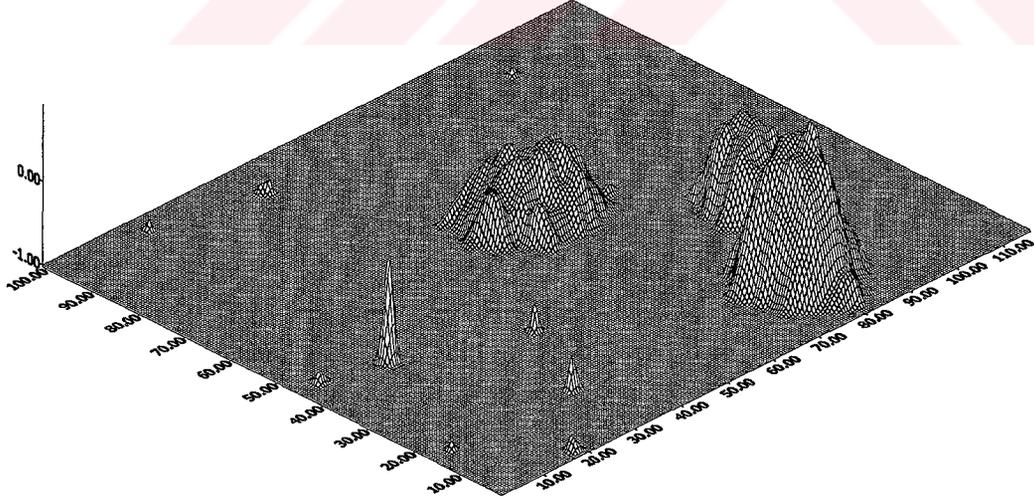


(b) Üç boyutlu görünüm

Şekil 7.17 Hitit uygarlığına ait arkeolojik görüntü



(a) HYSA sonucu



(b) Üç boyutlu görünüm

Şekil 7.18 Hitit uygarlığına ait arkeolojik görüntünün HYSA sonucu

8. SONUÇLAR

Bu tez çalışmasında, yeni yapay sinir ağı mimarileri ve öğrenme algoritmaları geliştirerek farklı özelliklere sahip verilerin işlenmesi uygulamaları üzerinde çalışılmıştır. Üzerinde çalışılan ağ yapıları, ileri beslemeli yapay sinir ağları ve hücrel yapay sinir ağıdır. Geliştirilen öğrenme algoritmasında ise geriye yayılım algoritması ve dalgacık teorisinden yararlanılmıştır. Bu yeni yapılar ve algoritmalar kullanılarak EMG işaretlerinin sınıflanması, fonksiyon yaklaşımı, aydınlık düzeyi hesabı gibi tek boyutlu işaretlerin işlenmesi ve görüntü kenar belirleme, jeofizik maden haritalarının ayrıştırılması, arkeolojik görüntülerin iyileştirilmesi gibi iki boyutlu işaretlerin işlenmesi uygulamaları gerçekleştirilmiştir.

8.1 Dalgacık Yapay Sinir Ağı

İleri yönlü ağlarda işlem birimi olarak dalgacık fonksiyonu kullanılmış ve bu ağ *Dalgacık Yapay Sinir Ağı* olarak adlandırılmıştır. DYSA'nın özellikle *yakınsama hızı* ve *daha küçük boyutlara indirgenebilmesi* gibi önemli avantajlar sağladığı görülmüştür. DYSA'nın performans analizi için aynı ağ yapısına sahip farklı aktivasyon fonksiyonları kullanan çok katmanlı ağlar ile karşılaştırmalar yapılmış ve aşağıdaki sonuçlar elde edilmiştir:

EMG Sınıflama - EMG işaretlerinin sınıflandırılmasında dört farklı kol hareketine ait işaretlerin eğitim hızları karşılaştırılmıştır. Gizli katman düğüm sayısının 7 seçildiği eğitimde DYSA'nın iterasyon sayısı 606, ÇKA²'nin 1333, ÇKA¹'in 9835 olduğu görülmüştür. Bu iterasyonlar pentium II-300 işlemcili bir PC'de sıra ile 25.6, 46.08, 420.72 saniye sürmüştür. Bu süreler göz önüne alındığında DYSA'nın eğitim hızının, hiperbolik tanjant sigmoid'in aktivasyon fonksiyonu olarak kullanıldığı ÇKA²'ye göre iki kat hızlı olduğu görülmektedir. Test aşamasında elde edilen sınıflama başarımının her bir ağ için ortalama %83.3 olarak aynı olduğu görülmüştür. Sınıflamada hareket sayısının ve giriş öznitelik vektörlerinin boyutlarının artması eğitim süresi üzerinde önemli oranlarda artmalara neden olacaktır. *Bu uygulamada elde edilen saniyeler ve dakikalar mertebesindeki süreler saatler mertebesine çıkacağından dolayı, DYSA'nın sağladığı eğitim hızı önemli bir avantaj sağlayacaktır.* Diğer ağların 10 düğümlü gizli katman kullanmasına karşılık DYSA aynı işlevi 5 düğümlü bir katman ile gerçekleyebilmektedir. *Böylelikle daha küçük ağ mimarileri ile çalışılması mümkün olabilmektedir.*

Fonksiyon Yaklaşımı - Fonksiyon yaklaşımında, bilinen bir fonksiyonun yerine kullanılacak, ağırlık ve aktivasyon fonksiyonları cinsinden ifade edilen yeni bir eşitliğin

bulunması hedeflenmiştir. Ayrıca öğrenme oranlarının etkisini de gözlemlemek amacı ile $\alpha=0.05$ ve $\alpha=0.1$ öğrenme oranları için eğitim ve test işlemleri gerçekleştirilmiştir. *Sonuçta DYSA'nın eğitim hızının $\alpha=0.05$ için ortalama üç kat ve $\alpha=0.1$ için iki kat olduğu görülmüştür.* Hata oranı eğitim esnasında aynı seçildiğinden dolayı test aşamasında her bir ağın sonuçları aynı hata ile elde edilmiştir.

Aydınlatma Düzeyi Hesabı - Aydınlatma problemlerinde karşılaşılan aydınlık düzeyi hesabında ışık dağılım eğrilerinden yararlanılır. Işık dağılım eğrilerinin, ölçüm sonucu elde edilen veriler kullanılarak ölçüm yapılmayan doğrultulardaki değerlerin belirlenmesinde yapay sinir ağları kullanılmıştır. Bu ağlar ile DYSA'nın eğitim ve test performansları karşılaştırılmıştır. Eğitim aşamasında, giriş veri sayısına göre yakınsama süreleri karşılaştırılmış ve altı verinin kullanıldığı eğitimde DYSA 5658, ÇKA² 14566, ÇKA¹'in 65000 iterasyon sonucunda yakınsadığı görülmüştür. Bu veriler ışığında DYSA'nın çok daha hızlı bir yakınsama sağladığı açıkça görülmektedir. DYSA'nın test aşamasında herbir noktaya karşılık gelen ışık şiddetleri bulunarak aydınlık düzeyi 'E'nin hesaplanması gerçekleştirilmiştir.

Bu üç uygulama sonucunda DYSA için şu iki önemli tesbiti yapmak mümkündür:

- 1) *DYSA'nın eğitim aşamasındaki yakınsama hızı aynı mimariye sahip diğer ağlara göre uygulama alnına bağlı olarak 2-3 kat fazla olabilmektedir.*
- 2) *DYSA'nın eğitim hızının yüksek olması gizli katman düğüm sayısının azaltılmasına olanak tanımaktadır. Böylelikle daha küçük mimariye sahip ağ yapıları elde edilebilmektedir.*

8.2 Dalgacık Öğrenme Algoritması ve Dalgacık Hücresel Yapay Sinir Ağı

Tez çalışmasının ikinci bölümünde dalgacık teorisinin hücresel yapay sinir ağlarında kullanımı ve HYSA için yeni bir öğrenme algoritmasının geliştirilmesi üzerinde durulmuştur. İleri yönlü ağlarda kullanılan geriye yayılım algoritmasının (GYA), HYSA için uyarlanması ve bu yeni algorithmada dalgacık fonksiyonunun kullanımı ile *Dalgacık Öğrenme Algoritması (DÖA)* elde edilmiştir. Bu öğrenme algoritmasının oluşturulmasında HYSA'nın dinamik yapısından dolayı GYA'da bir takım yeni düzenlemeler yapılmıştır. Bu düzenlemeler şu şekilde sıralanabilir:

- 1)Aktivasyon fonksiyonunun türev ifadesi yerine Meksika Şapkası dalgacığı kullanılmıştır.

- 2) Girişlerin çıkışla değişmesinden dolayı meydana gelen yakınsamama problemi, güncel ağırlıkları veren eşitlikte ilk girişin sabit olarak kullanılması ile çözümlenmiştir.
- 3) Eğitim aşamasında, ağın ileri işlem akışında HYSA'nın kendi yapısı kullanılarak kararlı durum çıkışı elde edilmiştir.

Dalgacık öğrenme algoritmasının oluşturulmasından sonra bu algoritma kullanılarak HYSA'nın yapısının küçültülmesi hedeflenmiştir. Bu amaçla HYSA'da kullanılan 2 adet 3 x 3 boyutlu A ve B şablonları eşit seçilerek eğitime işlemi yapılmıştır. Böylelikle:

- 1) *A ve B şablonları yerine kullanılabilir bir tane C şablonu bulunmuştur.*
- 2) *Eğitim aşamasında tek şablon kullanılması, ağırlık katsayılarının 11'den 6'ya inmesini sağlamıştır. Böylelikle eğitim hızı ve yakınsama performansı artmıştır.*
- 3) *İki şablon yerine tek bir C şablonunun kullanılabilmesi konvolüsyon işlemine de ikiden bire düşürmesi açısından test aşamasında işlem yükünü azaltmıştır.*
- 4) *Gerçek zamanda (Real - time) görüntü tanıma ve sınıflama uygulamalarında gerçekleştirme kolaylığı sağlanmıştır.*
- 5) *HYSA'nın önemli bir özelliği olan tümleşik devre olarak gerçekleştirilmesinde mimari küçülmesi büyük avantajlar sağlamıştır.*

DÖA'nın kullanımı ile elde edilmiş bu yeni ağ *Dalgacık Hücresel Yapay Sinir Ağı (DHYSA)* olarak adlandırılmıştır. DÖA ve DHYSA'nın kullanımı ile *farklı görüntü işleme uygulamalarına yönelik tasarım imkanı* elde edilmiştir. Bu tasarım performanslarının incelenmesi için kenar belirleme, jeofizik maden haritalarının ayrıştırılması ve arkeolojik görüntülerin iyileştirilmesi uygulamalar gerçekleştirilmiştir.

8.2.1 Kenar Belirleme

Kenar belirleme uygulaması için üç farklı görüntü kümesi üzerinde çalışılmıştır. Sonuçların değerlendirilmesinde klasik yöntemlerin verdiği sonuçlardan yararlanılmıştır.

Sentetik Görüntüler - DHYSA'nın görüntü kenar belirleme uygulaması için Paint Brush çizim programı kullanılarak elde edilmiş 236 x 236 boyutlu harf, rakam ve şekil görüntüleri kullanılmıştır. Bu uygulamalarda, ortalama 5-6 iterasyon sonucunda görüntülerin kenar bilgileri elde edilmiştir. Elde edilen bu sonuçların klasik kenar belirleme yöntemleri Canny, Sobel ve Laplasyen sonuçları ile karşılaştırılması yapılmıştır. Doku olarak basit yapılara sahip

olan bu görüntülerin Canny ve Laplasyen sonuçlarında kenar bozulmaları görülmüştür. *DHYSA ve Sobel yöntemleri ise hatasız bir şekilde kenarları belirlemiştir.*

Kamera Görüntüleri - İkinci uygulama olarak kamera ile alınmış ve 256 x 256 boyutlarında Tif formatında kaydedilmiş görüntüler kullanılmıştır. Önceki uygulamaya göre biraz daha kompleks bir dokuya sahip olan bu görüntülerin kenar belirlenmesi sonuçları karşılaştırıldığında *DHYSA ve Canny yöntemlerinin Sobel ve Laplasyene göre daha başarılı olduğu görülmüştür.*

Tıbbi görüntüler - Kenar belirlemenin bir çok uygulama alanı bulduğu tıbbi görüntü işlemede (Medical imaging) DHYSA'nın kullanımını incelemek amacı ile tümörlü bir beyne ait MR görüntüsü kullanılmıştır. Tıbbi açıdan, teşhis aşamasında tümörün büyüklüğü, zaman içinde genişleme oranı ve büyüme yönünün tespiti için kenar belirlemeye ihtiyaç vardır. Tedavi aşamasında ise radyoaktif terapinin uygulanacağı bölgenin alanının ve ışın konfigürasyonunun belirlenmesinde kenar belirleme önemlidir. Yapılan kenar belirleme uygulaması sonucunda *DHYSA'nın diğer klasik yöntemler ile birlikte başarılı sonuçlar verdiği görülmüştür.*

8.2.2 Jeofizik Verilerin Analizi

Hücrenel yapay sinir ağının bir öğrenme algoritması kullanılarak jeofizik verilerin işlenmesi uygulaması ilk kez bu tez çalışmasında gerçekleştirilmiştir. Eğitim aşamasına geçmeden önce sentetik jeofizik veriler oluşturulmuştur. Bu aşamada yeraltında değişik derinliklere yerleştirilmiş kürelerin, matematiksel bağıntılar kullanılarak yer üstü gravite haritasının elde edilmesi sağlanmıştır. Bu harita verileri HYSYA'ya giriş olarak verilmiş ve hedef olarak da tek bir kürenin gravite haritası alınmıştır. Eğitim aşaması sonucu bulunan şablon ve eşik katsayıları kullanılarak Dumluca bölgesine ait MTA tarafından elde edilmiş maden haritasının analizi yapılmıştır. *Bulunan sonuçlar klasik Haalck'ın türev metodu ile karşılaştırılmış ve HYSYA'nın iteratif filtreleme özelliği ile çok daha başarılı olduğu görülmüştür.*

8.2.3 Arkeolojik Görüntülerin Analizi

HYSYA'nın ilk kez uygulandığı diğer bir alan ise arkeolojik görüntü işlemedir. Arkeolojik görüntüler yer altındaki tarihi kalıntılar hakkında bilgi içeren ve daha çok bilgi edinilmesi için analiz edilmeye ihtiyaç duyulan verilerdir. HYSYA'nın sentetik veriler ile eğitilmesi sonucu elde edilmiş ağırlık katsayıları kullanılarak, gerçek görüntüler üzerinde test çalışmaları

yapılmıştır. Bu aşamada Hitit uygarlığının kalıntılarının bulunduğu Akhisar bölgesine ait görüntüler kullanılmıştır. *Ortalama 4-8 iterasyon sonucunda yer altındaki kalıntıların yükseltmelerini ve çerçevelerini veren görüntüler net bir şekilde elde edilmiştir.*



KAYNAKLAR

Akansu, A.N., Haddad, R. A., (1992), Multiresolution Signal Decomposition, Academic Press.,Boston, USA.

Akçığ, Z., Pınar, R., (1994), Gravite ve Manyetik Arama Yöntemleri, Dokuz Eylül Üniversitesi Mühendislik Fakültesi Yayınları, 249.

Albora, A. M., Uçan, O. N. ve Özmen, A., (1999), "Markov Random Field (MRF) Yöntemi Kullanarak Sivas Bölgesi Şarkışla Mevkiinin Ters Çözüm ile Modellenmesi", 20-23 Ekim 1999, 11.Mühendislik Haftası Yerbilimleri Sempozyumu Bildiri Özetleri, Isparta.

Albora, A. M., Özmen, A.,Uçan, O. N., (2000), "Extraction of Mine Deposit Areas in Sivas-Divriği Region Using Cellular Neural Network Approach.", 25-29 April 2000, European Geophysical Society XXV General Assembly, Nice, France.

Albora, A. M., Uçan, O. N., Özmen, A., (2000b), "Hücreyel Yapay Sinir Ağları Yöntemi Kullanarak Sivas-Divriği Bölgesi Akdağ Demir Cevherinin Rezervinin İncelenmesi", 8. IEEE Sinyal İşleme ve Uygulamaları Kurultayı (SİU'2000), Antalya, 90-95.

Albora, A.M., Özmen, A. ve Uçan, O. N., (2001), "Residual Separation of Magnetic Fields Using a Cellular Neural Network Approach", Pure and Applied Geophysics, 158: 1797-1818.

Albora, A. M., Uçan, O. N., Özmen, A. ve Özkan, T., (2001) "Separation of Bouguer Anomaly Map Using Cellular Neural Network", Journal of Applied Geophysics, 46:129-142

Albora, A.M., Uçan, O.N., Özmen, A. ve Özkan, T., (2001) "Evaluation of Sivas-Divriği Region Akdag Iron Ore Deposits Using Cellular Neural Network" Journal of Applied Geophysics

Bal, A.,(1997), Wavelet Yöntemi ile Ses Sıkıştırma, Yüksek lisans tezi, YTÜ FBE, İstanbul

Balsi, M. ve Voci, F., (2000), "Fuzzy Reasoning for the design of CNN-Based Image Processing Systems", ISCAS 2000, May 28-31,Switzerland, 405-409

Balsi, M. ve Racina, N., (1994), "Automatic Recognition of Train Tail Signs Using CNNs", CNNA-94, 18-21 Dec. 1994, Rome, Italy.

Bankman, I. N., Handbook of Medical Imaging, (2000), Academic Press, London, UK

Beck, R.M, Dölle, M., Höfer, H., Perner, P., Heywang, S.H. (2001), "High Performance Implementation of a Similarity-Based Image Segmentation Algorithm for Brain/Liquor Determination Automatic Segmentation of CT-Scans to Determine Brain/Liquor Ratios", Image Processing and Parallel Computing in Medical Applications, 37-43

Beolchi, L., Kuhn, M. H., (1995), Medical Imaging, IOS Press, USA

Bentley, P. ve Grant, P.,(1995), "Wavelet and wavelet transform", TFTS'95, 30-31 August, Coventry, UK, 13-22

Brause, W.Rudiger, (1996), "Sensor Encoding Using Lateral Inhibited Self-Organized Cellular Neural Networks", Neural Networks, Elseiver Science, 9(1):99-120

Chen, J. ve Itoh, S., (1998), "A Wavelet Transform-Based ECG Compression Method Guaranteeing Desired Signal Quality", IEEE Trans. on Bio. Eng., 12 Dec. 1998, 45:12

- Chen, C. W. ve Chen, L., (1998), "Cellular Neural Network Achitecture for Gibbs Random Field Based Image Segmantation", Journal of Electronic Imaging, Jan. 1998, 7(1):45-51
- Chua, L. O. ve Yang, L., (1988a), "Cellular Neural Networks: Theory", IEE Transactions On Circuits and Systems, Vol. 35, No.10, Sayfa 1257 – 1272.
- Chua L.O. ve Yang L., (1988b), "Cellular Neural Networks: Applications", IEEE Transactions on Circuits and Systems, Ekim 1988, 35 (10): 1273 – 1290.
- Chua L.O. ve Thiran P., (1991), "An Analytic Method For Designing Simple Cellular Neural Networks", IEEE Transactions on Circuits and Systems, Nov 1991, 38 (11): 1332-1341.
- Cimagalli V., (1993), "Cellular Neural Networks: A Review", Proceedings Of Sixth Italian Workshop on Parallel Architectures and Neural Networks, Vietri Sul Mare, Italy, 1-31.
- Civalleri, P. P., Gilli, M., ve Pandolfi, L., (1993), "On Stability of Cellular Neural Networks with Delay", IEEE Transaction on Circuits and Systems Fundamental Theory and Applications, March 1993,40 (3):157-165
- Çelebi, M.E.ve Güzeliş, C., (1995), "Lyapunov function based design of dynamical neural networks for restoration of blurred and noisy images"
- Daubechies, L., (1990), "The Wavelet Transform, Time-Frequency Localization and Signal Analysis", IEEE Trans. on Information Theory, 36.
- Derin, H. ve Elliot, A. H. (1987), "Modelling and Segmentation of Noisy and Textured Images Using Gibbs Random Field", IEEE Pami, 9: 39-55.
- Doğan, H., Yıldızeli N., Yurt, M.Z., Celebi, A. ve Özcan, H. (1989), T.D.C.I. Genel Mudurlugu adına, Sivas Divriği Cevresinde II-59, AR: 33613- Poligon-II. IR: 922 ruhsat alanlarında yapılan demir etudu jeoloji raporu. M.T.A Gen.Mud. 89/120 Ankara.
- Dokur, Z., (1999), "Yapay Sinir Ağları ve Genetik Algoritmalar Kullanılarak EKG Vurularının Sınıflandırılması", Doktora tezi, İTÜ FBE, İstanbul
- Ercan, A., ve Temizsöz, İ., (1998), "10x10 Metrelik Birim Kazı Peteğinde, Jeofiziğin Arkeolojik Kazıya Klavuzluğu: Hitit İmparatorluğu Dönemi", Külhöyük,Ankara. Jeofizik, 12
- Fedi, M, ve Quata, T, (1998), "Wavelet Analysis for The Regional-Residual and Local Selperstion at Potential Field Anomalies", Geophysical Prospecting, 46: 507-525.
- Geman S. ve Geman D., (1984), "Stochastic Relaxation, Gibbs Distributions, ve The Bayesian Restoration of Images", IEEE Pami, 6: 721-741.
- Graves, M., (2001), "Cardiac Magnetic Resonance Image Analysis", Image Processing and Parallel Computing in Medical Applications, 19-27
- Grossman, A., And Morlet, J., (1985), Mathematics And Physics, 2, L. Streit, Ed., World Scientific Publishing, Singapore.
- Güzeliş C., (1993), "Hücreyel Yapay Sinir Ağları ile Görüntü İşlenmesi", Tübitak Proje No: Eeeag – 103, Rapor, İstanbul,
- Engin Ş. N.,(1998) Condition Monitoring of Rotating Machinery Using Wavelets As A Pre-Processor To Artificial Neural Networks, Ph.D. London,

Erden F., (1979), Uygulamalı Gravite , MTA (Maden Tetkik Arama Enstitüsü Yayınlarından) Eğitim Serisi No: 21.

Ergin K., (1981), Uygulamalı Jeofizik, İstanbul Teknik Üniversitesi Yayınları, Sayı 1189.

Hagan, T.M., Demuth, H. B. ve Beale, M. (1995), Neural Networks Design, PWS Publishing Company, Boston, USA

Hecht-Nielsen, R., (1991), Neurocomputing, Addison-Wesley Publishing Company, USA.

Hertz, J., Krogh, A. ve Palmer, R.G., (1991), Introduction to The Theory of Neural Computation, Computation and Neural System Series, Addison, Wesley.

Hilton, L. M., (1997), "Wavelet and Wavelet Packet Compression of Electrocardiograms", IEEE Trans. on Biomedical Eng., 5 May 1997, 44:5

Jain, R. Kasturi R. ve Schunck B.G., (1995), Machine Vision, McGraw – Hill, Singapore

Jain, A.K., (1989), Fundamentals of Digital Image Processing, Prentice Hall, New Jersey

Karamahmut, S., (1994), Hücresel Yapay Sinir Ağları için İki Öğrenme Algoritması ve Görüntü İşleme Uygulamaları", Y.L. Tezi , İTÜ FBE., İstanbul

Karlsson, S., (1999) "Enhancement of Spectral Analysis of Myoelectric Signals During Static Contractions Using Wavelet Methods", IEEE Trans. on Biomedical Engineering, 46(6)

Karpe, M.A., (1998), "Die Hethitische Stadtruine Kusakli-Sarissa", Alma Mater Philippina, Marburger Universitätsbund, 1998, 21-26.

Kohonen T., Self Organization And Associative Memory, Second Edition, Springer Verlag.

Kozek T., Roska T., Chua L.O., (1993), "Genetic Algorithm for CNN Template Learning" IEEE Transactions on Circuits and Systems-I: Fundamental Theory And Applications, jun 1993, 40 (6): 392-402.

Laine A.F. ve Chang C.M., (1995), "De-Noising Via Wavelet Transforms Using Steerable Filters", Proc. IEEE Int. Sym. On Circuits and Systems, May 1995, 3:1956-1959.

Lim, S. J., (1990), Two-Dimensional Signal and Image Processing, Prentice- Hall, USA

Nossek J.A., (1996), "Design And Learning with Cellular Neural Networks", International Journal of Circuit Theory And Applications", 24: 15-24.

Matsumoto T., Chua L.O. ve Yokohama T., (1990a), "Image Thinning with A Cellular Neural Network", IEEE Transactions on Circuits and Systems, 37(5) : 638–640.

Matsumoto T., Chua L.O. ve Suzuki H., (1990b), "CNN Cloning Template: Connected Component Detector", IEEE Transactions on Circuits and Systems, 37(5): 633–635.

Matsumoto T., Chua L.O., Suzuki H., (1990), "CNN Cloning Template: Shadow Detector", IEEE Transactions on Circuits and Systems, Aug 1990, 37 (8): 1070–1073.

Mertzios, B. G., Spiliotis, I. M., Papademetriou, R.C., ve Tsirikolias, K., (1995), "Edge Extraction and Enhancement with Coordinate Logic Filters Using Block Represented Images" ECCTD'95 European Conference on Circuit Theory & Design, İstanbul, 1035-1039

Mısır İ., Demir N. ve Çağlar R., (1993) "Aydınlatma Armatürlerinin Işık Dağılım Eğrilerinin Ölçüm Yapılmayan Ara Değerlerinin Tespiti ve Tüm Eğrinin Temsili", Elmeksem'93, Bursa,

Muilkaich, M., Kondo K., ve Hamada, N., (1997), "Design of Nonlinear Cellular Neural Network Filters for Detecting Linear Trajectory Signals", IEICE Trans. Fundamentals, September 1997, E80-A(9):1655-1661

Muret, P. ve Omid, N., (1995), "Analysis of steepened magnetosonic waves using wavelet transforms and neural networks", Journal of Geophysical Research, December 1995, 100 (12):465-479

Özkaya M.,(1994), Aydınlatma Tekniği, Birsen Yayınevi, İstanbul,

Özmen A., Albora A.M. ve Uçan O.N., (1999a), "Hücrel Yapay Sinir Ağları (HYSA) Kullanarak Sivas Bölgesi Köttüyuttepe Mevkiinin Modellenmesi" 11. Mühendislik Haftası Yerbilimleri Sempozyumu Isparta, Ekim 1999, 373-381.

Özmen, A., Uçan, O.N. ve Albora A.M., (1999b), "Arkeolojik Sahalarda Ölçülen Cisimlerin Hücrel Yapay Sinir Ağları Kullanılarak Görüntülenmesi" Jeofizik Mühendisleri Odası İzmir Şubesi-İzmir,Eylül 1999, 24.

Özmen, A., (2001), Hücrel Yapay Sinir Ağı ve Görüntü İşleme Uygulamaları, Doktora Tezi, İ.Ü. FBE, İstanbul

Özyılmaz, L.B.,(2000), "Konik Kesit Fonksiyonlu Yapay Sinir Ağında Öğrenme Algoritmasının Geliştirilmesi ve Ağın Çeşitli Problemler için Performansı ile Duyarlılığının İncelenmesi", Doktora Tezi,YTÜ. FBE.,İstanbul

Park, J., Kim, H. Y. ve Lee, W. S., (2001), "A Synthesis Procedure for Associative Memories Based on Space-Varying Cellular Neural Networks", Neural Networks, Elsevier, 14:107-113

Quing, W., Xueqin, S., Quingxin Y., ve Weilli, Y., (1997), "Using Wavelet Neural Networks for the Optimal Design of Electro Magnetic Devices", IEEE Trans. on Magnetics, March 1997, 33(2):1928-19930

Rao, R.M. ve Bopardikar, A.S., (1998), Wavelet Transforms Introduction to Theory And Applications, Addison Wesley Longman,USA

Ramakrishnan, A.G., (1997), "ECG Coding by Wavelet-Based Linear Prediction", 12 Dec. 1997, IEEE Trans. on. Biomedical Eng., 44:12

Roska T. ve Et.Al., (1992), "Detecting Moving and Standing Objects Using Cellular Neural Networks", International Journal of Circuit Theory and Applications", 20: 613-628.

Savaci F.A. ve Vanderwalle J., (1993), "On The Stability Of Cellular Neural Networks", IEEE Transactions on Circuits And Systems, March 1993, 40 (3): 213 – 215.

Schultz A. ve Et.Al., (1998), "Spatio Temporal CNN Algorithm for Object Segmentation and Object Recognition", Fifth IEE International Workshop On Cellular Neural Networks and Their Applications Proceedings, Soth Bank University, Nisan 1998, London, UK, 347-352.

Shi B.E., Roska T. ve Chua L.O., (1993), "Design Of Linear Cellular Neural Networks For Motion Sensitive Filtering", IEEE Transactions On Circuits And Systems-II: Analog And Digital Signal Processing, May 1993, 40 (5): 320-331.

Shu-Kun H., Jean-Claude S. ve Chuen-Tien S., (1996), "High-Resolution Detection Of Geological Boundaries From Potential-Field Anomalies:An Enhanced Analytical Signal Technique". Geophysics, 61:373-386.

Simon H., (1999), Neural Networks , Prentice-Hall Inc.,New Jersey,USA.

Slot K., (1992), "Cellular Neural Network Design For Solving Specific Image-Processing Problems", *International Journal Of Circuit Theory And Applications*, 20: 629-637.

Suzuki H., Matsimoto T. ve Chua L.O., (1992), "A CNN Handwritten Character Recognizer", *International Journal of Circuit Theory And Applications*", 20: 601-612.

Sziranyi T., Csapodi M., (1994), "Texture Classification And Segmentation By Cellular Neural Network Using Genetic Learning", *Research Report, Computer And Automation Institute Hungarian Academy Of Sciences, Kasım 1994, Budapest, Hungary.*

Sziranyi, T. ve Czuni L., "Image Compression by Orthogonal Decomposition Using Cellular Neural Network Chips", www.sztaki.hu/~sziranyi/CNN_DinKod.html

Tander, B. ve Özmen A., (2000), "Kaotik Maskeleye ile Güvenli Haberleşme Simülasyonlarında Hücresel Sinir Ağı (HSA) Tabanlı Devrelerin Uygulamaları", 8. IEEE Sinyal İşleme ve Uygulamaları Kurultayı (SİU'2000), Antalya, Haziran 2000, 86-89.

Telford W.M., Geldart L.P., Sheriff R.E. ve Keys D.A. , (1981), *Applied Geophysics*, Cambridge University Press.

Uçan O.N., Özmen A., (1999), "Performance Of Gray Scaled Images Using Quantized Cellular Neural Network Combined Trellis Coded Quantization/Modulation (Qcnn-Cnn Ctcq/Tcm) Approach Over Rician Fading Channel", *International Conference On Telecommunications*, Korea, Jun 1999, 379-382.

Uçan, O.N., Şen, B., Albora, A.M. ve Özmen, A. (2000), "A New Approach to Gravity Anomaly Separation: Differential Markov Random Field (DMRF)", *Electronic Geosciences*
Uçan, O.N. ve Albora, A.M. (2000), "Markov Rastgele Alanlar Yöntemi Kullanılarak Elazığ-Gölalan Krom Sahasının İncelenmesi", *Uygulamalı Yerbilimleri Dergisi*, 6:107-117.

Uçan, O.N., Şen, B., Albora, A.M., Ve Özmen, A., (2000), "A New Gravity Anomaly Separation Approach: Differential Markov Random Field (DMRF)." *Electronic Geosciences*,5:1.

Ugur M., Ucan O.N., Kuntman A., Özmen A. ve Merev A., (1999), "Analysing The 2-D Surface Tracking Patterns By Using Cellular Neural Networks" *Conference On Electrical Insulation And Dielectric Phenomenia*, Austin, Texas, Sept. 1999, 154-157.

Venetianer, P. L. ve Roska, T., (2001), "Image Compression by Cellular Neural Networks", *IEEE CAS*,

Vetterli Martin, Kovacevic Jelena,(1995) *Wavelets And Subband Coding*, Prentice Hall, New Jersey, USA

Vilarino, D.L., Cabello D.,Balsi, M., ve Brea, V.M.,(1998), "Image Segmentation Based on Active Contours Using Discrete Time Cellular Neural Networks", *Fifth IEEE International Workshop on Cellular Neural Networks and Their Applications*, London, England, 14-17 April 1998, 331-339

Yang T. ve Chua L.O., (1996), "Secure Communication Via Chaotic Parameter Modulation", *IEEE Transactions On Circuits And Systems – I: Fundamental Theory And Applications*, Sept. 1996, 43(9): 817-819.

Yaoguo Li. ve Dogles W.O., (1998), "Separation Of Regional And Residual Magnetic Field Data", *Geophysics*, 63:431-439.

Zamparelli, M., (1997), "Genetically Trained Cellular Neural Networks", *Neural Networks*, 10 Nov. 1997, 10(6), 1143-1151

Zarandy A., (1999), "The Art of CNN Template Design", *International Journal Of Circuit Theory And Applications*, 27: 5-23.

Zarandy, A., Rekeczky, C., Csapodi, M. ve Roska, T., (1997), "Mammogram and Echocardiogram Analysis by Using Cellular Neural Network Technology", *Ercim News*, 29 April 1997.

Zhang, Q. ve Benveniste A., (1992), "Wavelet Networks", *IEEE Trans. On Neural Networks*, Nov. 1992, 3(6): 889-898

Zou F. ve Nossek J.A., (1991), "Stability Of Cellular Neural Networks with Opposite-Sign Templates", *IEEE Transactions On Circuits And Systems*, Jun 1991, 38 (6): 675 – 677.

Zou F. ve Nossek J.A., (1993), "Bifurcations And Chaos In Cellular Neural Networks", *IEEE Transactions On Circuits And Systems – I: Fundamental Theory And Applications*, March 1993, 40 (3): 166 – 173.



EKLER

- Ek 1 EMG İşaretlerinin Sınıflandırılması için Veritabanı
Ek 2 DHYSA Eğitim Programı
Ek 3 DHYSA Test Programı
Ek 4 Klasik Yöntemler ile Kenar Belirleme Programı



Ek 1 EMG İşaretlerinin Sınıflandırılması için Veritabanı

- Dört sınıf: Kolu içe hareket ettirme, kolu dışa hareket ettirme, dirsek açma, dirsek kapama
- Her sınıfa ait 6 örnek olmak üzere toplam 24 örnek;
- Her örnek 6 Ar katsayısı ile temsil edilmiştir.

Eğitim Kümesi Veritabanı

Emg 1_1 =[-0.7675 0.5117 0.0008 0.1069 -0.0386 0.1493];
 Emg 1_2 =[-0.5826 0.4955 -0.0032 0.2249 -0.0469 0.1840];
 Emg 1_3 =[-0.3953 0.4436 0.0505 0.1547 0.0873 0.0460];
 Emg 2_1 =[-0.3517 0.3887 0.1902 0.1696 0.0501 0.1324];
 Emg 2_2 =[-0.4169 0.4449 0.0651 0.1003 0.1580 0.1458];
 Emg 2_3 =[-0.4654 0.5561 0.0321 0.1990 0.0873 0.1628];
 Emg 3_1 =[-0.4771 0.0087 0.0399 0.0012 0.0874 0.1886];
 Emg 3_2 =[-0.5513 0.0147 0.0285 0.0040 0.0093 0.2644];
 Emg 3_3 =[-0.8843 0.3665 -0.0127 -0.0826 0.3350 0.0213];
 Emg 4_1 =[-1.0403 0.7811 -0.2009 0.3168 -0.0931 0.0372];
 Emg 4_2 =[-1.0644 0.8181 -0.2061 0.1862 -0.0320 0.1763];
 Emg 4_3 =[-1.0470 0.6900 -0.2121 0.2053 0.0398 0.0758];

Test Kümesi Veritabanı

Emg 1_4 =[-0.4901 0.3928 0.1138 0.0962 0.0437 0.0536];
 Emg 1_5 =[-0.4632 0.3445 0.1297 0.0983 0.1336 0.1166];
 Emg 1_6 =[-0.6037 0.5639 -0.0808 0.2505 -0.0527 0.1568];
 Emg 2_4 =[-0.3646 0.5404 0.2061 0.0245 0.1412 0.0784];
 Emg 2_5 =[-0.3976 0.5430 -0.0036 0.2329 0.0280 0.1738];
 Emg 2_6 =[-0.4103 0.4778 -0.0305 0.1305 0.1082 0.1032];
 Emg 3_4 =[-0.6568 0.1230 0.0707 0.0691 0.0142 0.1383];
 Emg 3_5 =[-0.9529 0.3233 0.1405 -0.0199 0.0550 0.0402];
 Emg 3_6 =[-0.7035 0.1820 0.0368 -0.0056 0.0568 0.1217];
 Emg 4_4 =[-1.1478 0.7179 -0.0735 0.2231 -0.1959 0.1978];
 Emg 4_5 =[-1.1069 0.6673 -0.0859 0.0018 0.1210 -0.0058];
 Emg 4_6 =[-1.0618 0.5975 -0.1447 0.2136 -0.1919 0.2094];

Ek 2 DHYSA Eğitim Programı

```

clear all

tic

baklava16 sekli

[v z]=size(yd);
boyut=v*z;
alfa=0.001; %Öğrenme oranı
is=1;
w=[-1 -1 -1 -1 4 -1];%Başlangıç ağırlık vektörü
limit=5000;
while is~=limit
a1=w(1); a2=w(2); a3=w(3); a4=w(4); a5=w(5);
I=w(6);
C=[a1 a2 a3;a4 a5 a4; a3 a2 a1];
i=2;
[k l]=size(x{1});
bir=ones(k,l);
y{1}=((1/2)*(abs(x{1}+bir)-abs(x{1}-bir)));
c=conv2(y{1}+x{1},C,'same');
x{2}=c+I;
while i~=50
y{i}=((1/2)*(abs(x{i}+bir)-abs(x{i}-bir)));
c=conv2(y{i}+x{1},C,'same');
x{i+1}=c+I;

%Kararlı durum çıkış kontrolu

yy=sum(sum(abs(y{i})));
if yy~=k*1

```

```

    i=i+1;
else
    it=i;
    i=50;
end
end

```

%Şablon matrislerinin vektörel yazılımı

```

ys=y{it};
u=x{1};
for i=1:v+2
for j=1:z+2
    if i==1 | j==1 | i==v+2 | j==z+2
        ys1(i,j)=0;
        u1(i,j)=0;
    else
        ys1(i,j)=ys(i-1,j-1);
        u1(i,j)=u(i-1,j-1);
    end
end
end
end
c=1;
for k=2:v+1
for l=2:z+1
    YS{c}=[ys1(k-1,l-1)+ys1(k+1,l+1)+u1(k-1,l-1)+u1(k+1,l+1);
    ys1(k-1,l)+ys1(k+1,l)+u1(k-1,l)+u1(k+1,l);
    ys1(k-1,l+1)+ys1(k+1,l-1)+u1(k-1,l+1)+u1(k+1,l-1);
    ys1(k,l+1)+ys1(k,l-1)+u1(k,l+1)+u1(k,l-1)];

```

```

    ys1(k,l)+u1(k,l);1]';
    c=c+1;
end
end

```

```

%Ağırlıkların ayarlanması

```

```

e1{is}=(ys-yd)/2;
e2{is}=sum(sum(yd-ys));
e3{is}=(ys-yd);
p=0;
n=0;
s=0;
for i=1:v
    for j=1:z
        deg=e1{is}(i,j);
        if deg>0.9
            p=p+1;
        elseif deg<-0.9
            n=n+1;
        elseif deg>-0.001 & deg<0.001
            s=s+1;
        end
    end
end
end
e{is}=-n+p;
if s~=boyut
    tt=1;
    toplam=0;

```

```

for ik=1:v
    for jl=1:z
        nn=x{2}(ik,jl);
        turev=((1-0.1*nn*nn)*exp(-2*nn*nn));
        xy=turev*YS{tt}*e3{is}(ik,jl);
        w=w-alfa*xy;
        tt=tt+1;
    end
end
w
s
is=is+1;
else
disp('eğitim tamamlandı')
bit=is
it
is=limit;
end
end
figure
imagesc(x{1})
title ('x-1')
figure
imagesc(y{it})
title ('y-it')

%Şablon ve Eşik değerlerinin saklanması

fid=fopen('c:\belgelerim\hysatek.txt','w');

```

```
fprintf(fid, '%f %f', C, I);
```

```
fclose(fid);
```

```
toc
```



Ek 3 DHYSA Test Programı

```
clear
AA=imread('harf_1a.tif');%Harf görüntüsünün okunması
xx=double(AA);
x{1}=xx;

%Dosyadan şablon ve eşik değerinin okunması

fid=fopen('c:\belgelerim\hysatek.txt','r');
C=fscanf(fid,' %f',[3 3]);
I=fscanf(fid,' %f',[1 1]);
fclose(fid);
i=2;
[k l]=size(x{1});
bir=ones(k,l);
y{1}=((1/2)*(abs(x{1}+bir)-abs(x{1}-bir)));
c=conv2(y{1}+x{1},C,'same');
x{2}=c+I;
while i~=1000
    y{i}=((1/2)*(abs(x{i}+bir)-abs(x{i}-bir)));
    c=conv2(y{i}+x{1},C,'same');
    x{i+1}=c+I;

%Kararlı hal çıkışı kontrolü

yy=sum(sum(abs(y{i})));
if yy~=k*l
    i=i+1;
else
```

```
it=i;  
i=1000;  
end  
end  
disp('iterasyon sayısı')  
it  
figure  
imagesc(-1*y{it});colormap(gray)  
title ('y-it')
```



Ek 4 Klasik Yöntemler ile Kenar Belirleme Programı

```
clear
m=menu('KENAR BELİRLEME YÖNTEMLERİ','SOBEL','CANNY','LAPLASYEN');
AA=imread('harf.tif');
figure;
imagesc(AA);
colormap(gray)
switch m
case 1, q=edge(AA,'sobel',[]);cc=double(q);
figure
imagesc(-1*cc)
colormap(gray)
case 2, q=edge(AA,'canny',[]);cc=double(q);
figure
imagesc(-1*cc)
colormap(gray)
case 3, q=edge(AA,'log',[]);cc=double(q);
figure
imagesc(-1*cc)
colormap(gray)
break;
end
switch m
case 1, title('sobel')
case 2, title('canny')
case 3, title('laplasyen')
break;
end
```

ÖZGEÇMİŞ

Doğum tarihi	01.04.1970	
Doğum yeri	İstanbul	
Lise	1985-1988	Haydarpaşa Teknik Lisesi, Elektronik Bölümü
Lisans	1988-1993	İ.T.Ü Elektronik ve Hab. Müh. Bölümü
Yüksek Lisans	1995-1997	Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektrik Müh. Bölümü, Kontrol ve Kum. Sist. ABD
Doktora	1997-	Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektrik Müh. Bölümü, Kontrol ve Kum. Sist. ABD

Çalıştığı kurum

1998 - Devam ediyor YTÜ Elektrik Müh. Bölümü Araştırma Görevlisi